

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky  
a komunikačních technologií

BAKALÁŘSKÁ PRÁCE



# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

## FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

## ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

## DETEKCE KOMOROVÝCH EXTRASYSTOL V EKG

DETECTION OF PREMATURE VENTRICULAR CONTRACTIONS IN ECG

### BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

### AUTOR PRÁCE

AUTHOR

Marek Kantor

### VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Petra Novotná

BRNO 2020

## ABSTRAKT

Tato práce se zabývá problematikou detekčních metod extrasystol z EKG signálu a popisu elektrokardiogramu, převodního systému srdečního, extrasystol a komorový tachykardií. Extrasystoly jsou předčasné komorové stahy způsobené ektopickými ložisky. Klasifikace je založena na předzpracování signálu, detekci píku R, segmentaci, výběru příznaků pro jednotlivé metody, normalizaci příznaků a učebním algoritmu pro klasifikaci. Vybrané a realizované metody dosahují přesnosti  $ACC = 98 \%$ , senzitivity  $SE = 100 \%$  a specifity  $SP = 96,1 \%$ . Získané příznaky byly rovněž využity pro detekci bloků Tawarova raménka.

## KLÍČOVÁ SLOVA

elektrokardiogram, EKG, komorová extrasystola, KES, komorová tachykardie, detekce KES, detekce bloků Tawarova raménka, BBB

## ABSTRACT

This thesis focusses on the detection methods of extrasystoles from ECG and description of electrocardiogram, cardiac conduction system, extrasystoles and ventricular tachycardia. Extrasystoles are premature ventricular contraction caused by ectopic heartbeats. Classification is based on signal preprocessing, detection of R peak, the heartbeat segmentation, the feature description methods, normalization of features and the learning algorithms used. Selected and realized methods achieved classification accuracy  $ACC = 98 \%$ , sensitivity  $SE = 100 \%$  and specificity  $SP = 96,1 \%$ . Gained features are also used for detection bundle branch block.

## KEYWORDS

electrocardiogram, ECG, ventricular extrasystole, PVC, ventricular tachycardia, PVC detection, detection of bundle branch block, BBB

KANTOR, Marek. *Detekce komorových extrasystol v EKG*. Brno, 2020, 66 s. Bakalářská práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce: Ing. Petra Novotná

## PROHLÁŠENÍ

Prohlašuji, že svou bakalářskou práci na téma „Detekce komorových extrasystol v EKG“ jsem vypracoval samostatně pod vedením vedoucího bakalářské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené bakalářské práce dále prohlašuji, že v souvislosti s vytvořením této bakalářské práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno .....

.....

podpis autora

## PODĚKOVÁNÍ

Rád bych poděkoval vedoucí bakalářské práce paní Ing. Petře Novotné za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci.

# Obsah

Úvod	11
<b>1 Srdce</b>	<b>12</b>
1.1 Srdeční cyklus	12
1.2 Převodní srdeční systém	13
1.3 EKG křivka	14
1.4 Popis EKG křivky zdravého srdce	15
1.4.1 P vlna	15
1.4.2 QRS komplex	15
1.4.3 T vlna	15
1.4.4 PQ interval	15
1.4.5 ST interval	16
<b>2 Extrasystoly</b>	<b>17</b>
2.1 Vznik komorových extrasystol	17
2.2 Popis komorových extrasystol	17
2.2.1 Dle místa vzniku	17
2.2.2 Dle načasování	18
2.2.3 Dle frekvence	18
2.2.4 Dle síňové aktivity	19
<b>3 Komorové tachykardie</b>	<b>20</b>
3.1 Monomorfní komorové tachykardie	20
3.1.1 Vznik	20
3.1.2 Léčba	20
3.2 Polymorfní komorová tachykardie	21
3.3 Fibrilace komor	21
3.4 Arytmie	22
3.5 Srdeční blokády	22
3.5.1 AV blokáda prvního stupně	22
3.5.2 AV blokáda druhého stupně	23
3.5.3 Kompletní srdeční AV blokáda	23
3.5.4 Blokáda pravého nebo levého Tawarova raménka.	23
<b>4 Současné metody předzpracování signálu EKG</b>	<b>24</b>
4.1 Předzpracování	24
4.1.1 Typy rušení	25
4.1.2 Filtrace	26

4.2	Segmentace a statistické termíny . . . . .	26
4.2.1	Přesnost segmentace . . . . .	26
4.2.2	Detekce R píku . . . . .	27
4.2.3	Segmentace . . . . .	27
<b>5</b>	<b>Výběr příznaků ze signálu EKG</b>	<b>28</b>
5.1	Metody pro hledání příznaků . . . . .	28
5.1.1	Skupina RR příznaků . . . . .	28
5.1.2	Skupina intervalových příznaků. . . . .	28
5.1.3	Skupina morfologických příznaků. . . . .	29
5.1.4	Zhodnocení . . . . .	30
5.2	Statistické metody pro korekci množství příznaků . . . . .	30
5.2.1	Metoda PCA . . . . .	30
5.2.2	Metoda ICA . . . . .	32
5.2.3	Vlnková transformace . . . . .	32
5.3	Klasifikace . . . . .	33
5.3.1	Lineární diskriminant . . . . .	33
5.3.2	Umělá neuronová síť . . . . .	33
5.3.3	Metoda podpurných vektorů . . . . .	36
5.3.4	Metoda k nejbližších sousedů . . . . .	37
<b>6</b>	<b>Praktická část práce</b>	<b>38</b>
6.1	Vstupní data a jejich předzpracování . . . . .	38
6.1.1	Předzpracování . . . . .	39
6.1.2	Normalizace příznaků . . . . .	40
6.2	Metoda přibližného rozměření . . . . .	41
6.3	Metoda s využití PCA . . . . .	46
6.4	Metoda dle starších studií . . . . .	49
6.5	Kombinace příznaků . . . . .	51
6.6	Rozpoznání KES a BBB . . . . .	51
<b>7</b>	<b>Výsledky</b>	<b>53</b>
<b>8</b>	<b>Diskuze</b>	<b>55</b>
	<b>Závěr</b>	<b>59</b>
	<b>Literatura</b>	<b>60</b>
	<b>Seznam symbolů, veličin a zkratk</b>	<b>64</b>

<b>A</b>	<b>Obsah elektronických příloh</b>	<b>65</b>
A.1	Vstupní data - databáze ÚBMI . . . . .	65
A.2	Seznam funkcí a potřebných dat ke klasifikaci . . . . .	65
A.3	Seznam vytvořených klasifikátorů . . . . .	66



# Seznam obrázků

1.1	Srdeční mechanika, převzato z:[1]	12
1.2	Srdeční práce v závislost na EKG, převzato z:[5]	13
1.3	Převodní systém srdeční, převzato z:[6]	14
1.4	Elektrokardiogram, převzato z:[17]	15
2.1	Síňová extrasystola, převzato z:[11]	17
2.2	Unifokální KES, převzato z:[11]	18
2.3	Multifokální KES, převzato z:[10]	18
2.4	R na T KES, převzato z:[11]	18
2.5	End-diastolická KES, převzato z:[11]	18
2.6	Interpolovaná KES, převzato z:[11]	18
2.7	Příklad bigeminie a trigeminie, převzato z:[10]	19
2.8	Příklad kupletů a salvy, převzato z:[10]	19
3.1	Supraventrikulární tachykardie, převzato z:[10]	20
3.2	Polymorfní tachykardie, převzato z:[10]	21
3.3	Komorová fibrilace, převzato z:[10]	22
3.4	AV blok prvního stupně, převzato z:[10]	22
3.5	AV blokáda třetího stupně, převzato z:[10]	23
3.6	AV blokáda druhého stupně, převzato z:[10]	23
4.1	Postup detekce, převzato z: [17]	24
4.2	Demonstrace vlivu rušení na signál EKG.	25
5.1	Pozice QRS offset/onset, T wave offset, pre RR interval a post RR interval, převzato a upraveno z: [17]	29
5.2	Morfologické znaky (vpravo) a interpolace EKG signálu, převzato a upraveno z: [17][25]	30
5.3	Model neuronu/ perceptronu (vpravo) a sigmoidální funkce perceptronu, převzato a upraveno z: [34],[35]	34
5.4	Dvouvrstvá perceptronová síť, převzato z: [34]	35
5.5	Znázornění hraniční přímky a tolerančního pásma, převzato z: [36]	36
5.6	k-NN; k=3, převzato z: [36]	37
6.1	Filtrace signálu	39
6.2	Rozměření signálu, převzato z: [37]	41
6.3	Blokové schéma metody přibližného rozměření	42
6.4	Křivka vzniklá mediánovou filtrací	42
6.5	Pozitivní a negativní signál	43
6.6	Hledání pozic maxima/minima jednotlivých kmitů	43
6.7	Přibližné rozměření N signálu	45
6.8	Přibližné rozměření KES signálu	45

6.9	Blokové schéma metody PCA zarovnaných segmentů . . . . .	46
6.10	Segmentace signálu . . . . .	47
6.11	Míra reprezentativnosti podle hlavních komponent . . . . .	48
6.12	Blokové schéma metody dle starších studií . . . . .	50
8.1	Srovnání metod . . . . .	55
8.2	Srovnání klasifikátorů . . . . .	56
8.3	Přibližné určení patologických kmitů . . . . .	57
8.4	Chybovost klasifikátorů N, KES a BBB signálů . . . . .	58

# Seznam tabulek

6.1	Hledání optimální filtrace . . . . .	40
6.2	Příznaky: přibližné rozměření; klasifikátor: Dopředná neuronová síť .	46
6.3	Hledání optimalní struktury neuronové sítě, pro metodu PCA (II svod)	48
6.4	Hledání optimalní struktury neuronové sítě, pro metodu PCA (II, V1, V6 svod) . . . . .	48
6.5	Hledání optimálního k počtu sousedů- metoda PCA; klasifikátor KNN	49
6.6	Metody dle starších studií; Příznaky: RR- intervaly, amplitudy, kore- lace, klasifikátor: NN . . . . .	51
6.7	Příznaky: Přibližné rozměření + PCA metoda; klasifikátor: Dopředná neuronová síť . . . . .	51
7.1	Vyhodnocení klasifikace KES . . . . .	53
7.2	Vyhodnocení klasifikace BBB, KES a N . . . . .	54

# Úvod

Detekce komorových extrasystol v EKG.

Tato práce se věnuje především detekci komorových extrasystol a elektrokardiogramu (EKG). Extrasystoly jsou vzruchy, které vznikají předčasně v AV uzlu nebo srdečních komorách. Dále se zabývá srdečními arytmiemi a komorovými tachykardiemi, které jsou definovány jako čtyři rychle po sobě jdoucí ektopické stahy. Jednou z možností léčby pacienta je radiofrekvenční ablace.

V této práci se pojednává o současných detektorech KES a jejich možném provedení. Byly realizovány tři metody pro výběr příznaků a následně použity tři typy klasifikátorů. Nejlepších výsledků dosahuje metoda s využitím PCA zarovnaných segmentů s klasifikátorem dopředná neuronová síť. Tento postup dosahuje přesnosti klasifikace  $ACC = 98,5 \%$ , senzitivity  $SE = 100,0 \%$  a specifity  $SP = 96,1 \%$ . Detekce komorových extrasystol je procesem, kterému předchází předzpracování, segmentace, výběru příznaků, normalizace a následná klasifikace.


# 1 Srdce

Srdce je dutý fibromuskulární orgán uložený v hrudníku. Je obaleno perikardem tzv. vazivovým vakem. Srdeční stěny jsou složeny z myokardu tvořící čtyři srdeční dutiny. Jedná se jak o pravou a levou síň, tak o pravou i levou komoru. Zevně je myokard pokrytý endokardem. Srdce dospělého člověka váží 250–390 g. [1]

Srdce v krevním oběhu slouží jako pumpa. Je tvořeno dvěma spojenými čerpadly, kterými jsou levá a pravá komora. Pravá komora má tenčí stěnu a zprostředkovává nízkotlakový plicní oběh, kde odvádí odkysličenou krev do plic. Levá komora odvádí okysličenou krev do těla. Oběhy jsou tvořeny tepnami, kapilárami a žilami a žíly. Srdce je vyživováno koronárními tepnami. [2]

## 1.1 Srdeční cyklus


Čerpací funkce je dána pravidelným střídáním systoly a diastoly. Ve fázi diastoly se srdce plní a při systole dochází k srdeční kontrakci s následným vypuzením krve. (viz. Obr. 1.1) [3] Srdeční systola je dána izovolumickou kontrakcí a ejekční fází. Izovolumická kontrakce znamená zvyšování nitrokomorového tlaku, při konstantním objemu krve v komoře. V tomto okamžiku jsou cípate chlopně uzavřeny. Překročí-li nitrokomorový tlak hodnotu diastolického tlaku, dojde k otevření poloměsíčitých chlopní a krev je vypuzována do velkého a malého tělního oběhu. Tato fáze se nazývá fází ejekční. Nitrokomorový tlak roste až do poloviny doby této fáze a následně klesá. Při poklesu tlaku na úroveň tlaku v tepnách se poloměsíčité chlopně uzavřou. Nitrokomorový tlak v levé komoře dosahuje hodnot 120–140 mmHg a v pravé komoře 20–30 mmHg. V ejekční fázi srdce vypudí přibližně 70 ml krve do velkého tělního oběhu.



Obr. 1.1: Srdeční mechanika, převzato z:[1]

Následná diastola začíná izovolumickou relaxací. Relaxací myokardu dojde k poklesu tlaku v komorách. Sníží-li se nitrokomorový tlak na hodnotu tlaku v síni, dojde k otevření cípate chlopní a prostřednictvím tlakového gradientu se plní komory –

plnicí fáze. Poté opět nastává systola síní a proces se opakuje. Srdeční revoluce trvá přibližně 0,85 s. Srdeční frekvence se pohybuje u zdravého jedince mezi 50 a 80 tepy za minutu. [1] [3]




Obr. 1.2: Srdeční práce v závislost na EKG, převzato z:[5]

## 1.2 Převodní srdeční systém

Podnět pro srdeční kontrakci vzniká v převodním srdečním systému.(viz.Obr 1.3) Zde je zastoupeno několik typů buněk. Nodální myocyty tzv. pacemakerové buňky udávají srdeční frekvenci. Nacházíme je v sinoatriálním uzlu (SA uzel) a atrioventrikulárním uzlu (AV uzel), kde vzniká podnět pro srdeční stah. Myocyty jsou uloženy v síti kolagenových a elastických vláken. Tranzitní myocyty a Purkyňovy kardiomyocyty umožní rychlý přenos vzruchů pomocí gap junction – skulinového spojení.[1] Skulinové spojení umožňuje přímou difuzi iontů a malých molekul mezi sousedními buňkami.[4] Za fyziologických podmínek vzruch vzniká v SA uzlu, který je srdeční pacemaker. Je uložen v blízkosti ústí horní duté žíly. Udává sinusový rytmus, který je dán spontánní aktivitou srdce.[2] Elektrický vzruch se šíří svazkem vláken do atrioventrikulárního uzlu (AV uzel). Následně impuls prochází Hisovým svazkem, z něhož odstupuje levé a pravé Tawarovo raménko. Raménka a jeho svazky vláken jsou uloženy pod endokardem septa. Následně přechází v Purkyňova vlákna. Akční napětí v SA uzlu a AV uzlu je dáno proudem  $Ca^{2+}$  a částečně  $Na^{+}$  iontů.

Rychlost šíření vzruchů se liší na základě průchozí tkáně. Nejrychleji je vzruch veden v Purkyňových vláknech, které vedou vzruch v komorách rychlostí 4 m/s. Rychlostí 1 m/s vede elektrický vzruch Hisův svazek, síňové dráhy a myokard komor. Nejpomaleji je veden vzruch v SA uzlu a AV uzlu a to rychlostí 0,05 m/s. [7]

### Cardiac Conduction System



Obr. 1.3: Převodní systém srdeční, převzato z:[6]

## 1.3 EKG křivka

Záznam elektrické aktivity srdce nazýváme elektrokardiogram (EKG). Jedná se o snímání neinvazivní metodou. Tělo je elektricky vodivé a proto lze elektrické projevy srdce měřit na povrchu těla. Amplituda jednoho svodu EKG je dána rozdílem potenciálu mezi dvojicí elektrod. Elektrická aktivita srdeční předchází mechanickou aktivitu srdce.[7]

V roce 1895 Dr. Willem Einthoven vynalezl přístroj pro snímání EKG. Naměřený signál následně popsal. Za tento objev získal Nobelovu cenu roce 1924.[8]


Snímání EKG rozdělujeme na klidové, zátěžové pro diagnostiku ischemické choroby srdeční (ISCH), dlouhodobé známé jako holterovské a fetální. Standardně se používá dvanácti svodové snímání EKG z důvodu zavedené interpretace signálu. Další možností je snímání pomocí trojice ortogonálních svodů. Příkladem je Frankův systém. [9] Ischemická choroba srdeční je projevem ischemie, tedy krevní nedostatečnosti srdce. Na signálu EKG pozorujeme změny na ST úseku.[10][11] Končetinové svody, jsou připevněny na zápěstích a levé dolní končetině jsou označovány jako Einthovenův trojúhelník, který má ve svém středu srdce. Jedná se o bipolární snímání, tedy pomocí dvou aktivních elektrod[7] Je zde zapojená také zemnicí elektroda, která je připevněna na pravé dolní končetině. Dále snímáme EKG pomocí unipolárních svodů. Jejich součástí jsou hrudní svody označovány jako (V1-V6). Zaznamenávají napětí vzhledem k indifferenční elektrodě, zde Wilsonové svorce. Goldbergovy svody (aVR, aVF, aVL) měří potenciál mezi elektrodou a průměrem potenciálu zbylých elektrod Einthovenova trojúhelníku.[9]

## 1.4 Popis EKG křivky zdravého srdce

EKG křivka zdravého jedince obsahuje vlnu P, komplex QRS a vlnu T. (viz.Obr 1.4)

### 1.4.1 P vlna

P vlna reprezentuje depolarizací síní. Dle přítomnosti vlny stanovujeme, zda se jedná o sinusový rytmus. Vycházíme z předpokladu, že SA uzel se nachází na vyústí horní duté žíly, a tedy depolarizace komory postupuje směrem dolů k AV uzlu. Vlna P by tedy měla být pozitivní ve svodech (II, III a aVF) v dolní části srdce a negativní ve svodu (V1) v horní části srdce.



Obr. 1.4: Elektrokardiogram, převzato z:[17]

### 1.4.2 QRS komplex

Komplex QRS reprezentuje depolarizací komor. Doba trvání je do 0,10 s. V QRS komplexu je skrytá repolarizace síní. Kladný kmit značíme písmenem R a záporné kmity jsou označeny písmeny Q a S. Vlna R má nejvyšší amplitudu, dosahuje amplitudy jednotek milivoltů.

### 1.4.3 T vlna

Vlna T je dána repolarizací komorového myokardu.

### 1.4.4 PQ interval

PQ interval odpovídá převodu vzruchů ze síní na komory prostřednictvím AV uzlu, který je jediným elektricky vodivým spojením mezi síněmi a komorami. Zároveň je



nejpomalejším místem srdečního převodního systému. Délka PQ intervalů bývá v rozmezí od 0,12 - 0,21 s. [11]

#### **1.4.5 ST interval**

Úsek ST nastává po depolarizaci komor. Doprovází fáze plato, a tím způsobí nulovou elektrickou aktivitu srdce po dobu 0,20 s. [12]

## 2 Extrasystoly

Extrasystoly jsou vzruchy, které vznikají předčasně v AV uzlu nebo komorách.

Síňové extrasystoly bývají převedeny přes AV uzel a Tawarovými raménky na komory. V důsledku je QRS komplex štíhlý. Vlna P je předčasná, velice často nasedá na vlnu T. V případě, že vlna P nasedne na vlnu T dojde k deformaci obou vln. Komplex QRS bývá nepozměněn. [13]



Obr. 2.1: Síňová extrasystola, převzato z:[11]

U komorových extrasystol (KES) vzruch předčasného komorového stahu neprochází Hisovým svazkem, Tawarovými raménky a Purkyňovými vlákny, ale vzniká v ektopických ložiskách myokardu. Důsledkem je předčasný široký QRS komplex ( $>0,12$  s) s abnormálním vzhledem, bez P vlny.

### 2.1 Vznik komorových extrasystol

Příčiny KES jsou např. infarkt myokardu, ischemie myokardu, hypertenze, myokarditida, chlopenní vadoa, kardiomyopatie. KES vznikají v důsledku bloků převodního systému srdečního. Vzruch následně nevzniká v SA uzlu, ale dále v převodním systému srdečním či myokardu. [7]

### 2.2 Popis komorových extrasystol

#### 2.2.1 Dle místa vzniku

Tvar extrasystoly souvisí s anatomickým místem vzniku vzruchu. Vzniká-li vzruch ve stejném místě, průběh KES má stále stejný tvar. Tyto extrasystoly nazýváme **unifokální** (viz. Obr. 2.2). Extrasystoly s rozdílnými místy vzniku vzruchu způsobí rozdílné průběhy šíření elektrické aktivity na komorách. Projevem je rozdílný tvar QRS komplexu a odlišný průběh depolarizace komor. Tyto extrasystoly nazýváme jako **multifokální** (viz. Obr. 2.3).



Obr. 2.2: Unifokální KES, převzato z:[11]

**Multifocal PVCs**



Obr. 2.3: Multifokální KES, převzato z:[10]

### 2.2.2 Dle načasování


Předčasné extrasystoly mohou nasedat na vlnu T. Tyto komorové extrasystoly označujeme jako **R na T** (viz. Obr. 2.4). Komorová extrasystola R na T může způsobit fibrilaci komor. Pokud extrasystola nastane neprodleně po vlně P z SA uzlu, označujeme ji jako **end-diastolická** (viz. Obr. 2.5). Po předčasné extrasystole bývá kompenzační pauza, pokud tak není a v této pauze vznikne další KES, jedná se o extrasystolu **interpolovanou** (viz. Obr. 2.6).




Obr. 2.4: R na T KES, Obr. 2.5: End-diastolická KES, Obr. 2.6: Interpolovaná KES, převzato z:[11] KES, převzato z:[11] převzato z:[11]

### 2.2.3 Dle frekvence

Udává, jak často nastane KES. **Bigemií** (viz. Obr. 2.7) popisujeme část signálu, kde každý druhý stah je KES. Tudíž za každým normálním QRS komplexem nastupuje KES. **Trigeminie** (viz. Obr. 2.8) označuje událost, kdy každá třetí kontrakce je KES. **Kuplet** (viz. Obr. 2.9) označuje dvě komorové extrasystoly jdoucí za sebou. Více než dvě KES za sebou označujeme jako **salva** (viz. Obr. 2.10).



Obr. 2.7: Příklad bigeminie a trigeminie, převzato z:[10]



Obr. 2.8: Příklad kupletů a salvo, převzato z:[10]

## 2.2.4 Dle síňové aktivity


Pokud AV uzel převedl komorový vzruch na síně, vlna P je skrytá v KES. Nepřevádí-li AV uzel vzruch, aktivita síní není závislá na komorách, tehdy následuje úplná kompenzační pauza. Proniká-li vzruch částečně do AV uzlu, může dojít k přímému převedení na prodloužený QR interval. Tento jev se objevuje po interpolovaných extrasystolách a nazýváme jej **skryté retrográdní vedení**. [11]

## 3 Komorové tachykardie

Komorová tachykardie je definovaná jako čtyři rychle po sobě jdoucí ektopické stahy. Rozdělujeme je na monomorfní komorové tachykardie a polymorfní komorové tachykardie.

### 3.1 Monomorfní komorové tachykardie

Je dána rychle za sebou jdoucími KES s pravidelným rytmem, které jsou unifokální. QRS komplexy jsou opět velice široké a frekvence dosahuje až 250 min. (viz. Obr 3.1) Tato tachykardie může vést ke smrti pacienta. Síňová aktivita bývá pomalá a nezávislá na komorovém stahu. Vlna P je skryta v QRS komplexu, nebo chybí.



Obr. 3.1: Supraventrikulární tachykardie, převzato z:[10]

#### 3.1.1 Vznik

Tachykardie nejčastěji vznikají v důsledku reentrů nebo automacií. Reentry jsou anatomicky dány překážkou, kolem které se vzruch šíří v kruhu. Standardní excitační impuls odezní po depolarizaci, je-li překážka (skupina vláken) nedepolarizována může se obnovit vzruch.[14] Automacie je dána samovolnými vzruchy o vyšší frekvenci než je frekvence vycházející z SA uzlu. Dochází k předčasným stahům, které narušují rytmus.


#### 3.1.2 Léčba

**Kardiostimulace** – Jedná se zde o stimulaci overdrive, kdy se po dobu několika sekund zvyšuje HB. Stimulována srdeční frekvence je vyšší než frekvence KES. Může dojít k vyvolání fibrilace komor. Pacientům se implantuje kardioverter defibrilátor (ICD), který slouží jako kardiostimulátor, či jako defibrilátor s výboji stejnosměrného proudu. **Perorální léky** se používají v akutních případech. Mají i mnoho

negativních účinků. Používají se amiodaron, sotalol či betablokátory. **Katétrová ablace** se používá k léčbě supraventrikulárních, síňových a komorových tachykardií. Je velice efektivní a často používaná. Do pravé stehenní žíly (vena femoralis) je zaveden katetr a v srdci je vypalováno místo s patologickou elektrickou vodivostí. Nevýhodou je, že vypálené jizvy mohou vytvořit nové komplikace v podobě reentrů. Zdrojem energie je střídavý proud o frekvenci 30 kHz až 300 MHz.[15] **Chirurgická léčba** – je velice náročná, často vede k transplantacím

## 3.2 Polymorfní komorová tachykardie

Podobně jako monomorfní komorové tachykardie obsahuje za sebou jdoucí komorové extrasystoly, které jsou multifokální(viz.Obr 3.2). Rozeznáme je podle měnící se amplitudy KES. Mezi tyto tachykardie patří rovněž tachykardie **Torsade de Pointes**, u které dochází k prodlužování QT intervalu. QT interval je prodlužován z důvodu hypokalcémie, ischemii a hypotyreózy. U této arytmie je nutno odstranit příčinu prodlužování QT intervalu, jiná léčba může být kontraproduktivní.




Obr. 3.2: Polymorfní tachykardie, převzato z:[10]

## 3.3 Fibrilace komor

Jedná se o rychlé a nekontrolované systoly(viz.Obr 3.2). Srdce není schopno pumpovat krev a způsobuje zástavu oběhu. Ze signálu nelze identifikovat QRS komplex z důvodu chaotické elektrické aktivity. Je nejčastějším důvodem úmrtí spojeným se srdečními komplikacemi. Taktéž je projevem infarktu, poruchou vedení elektrického proudu a syndromem Brugadových. Fibrilace je zastavena rychlou defibrilací.[10][11] Syndrom Brugadových je vzácná genetická porucha sodíkových kanálků. Na EKG signálu se projevuje elevací ST úseku.[11]



### Ventricular Fibrillation (VF)



Obr. 3.3: Komorová fibrilace, převzato z:[10]

## 3.4 Arytmie

Stah zdravého srdce je dán šířením impulsu z SA uzlu. Jedná se tedy o sinusový rytmus. Zpomalení srdeční frekvence pod 60 tepů/minutu se nazývá bradykardie a zrychlení nad 100 tepů/minutu je tachykardie. Změny v srdeční frekvence jsou v jisté míře fyziologické. Frekvence se zpomalí při spánku a odpočinku, naopak zrychlení frekvence způsobí emoce, pracovní nasazení. Taktéž se zrychluje při vdechu a zpomaluje při výdechu, zde je způsobená vlivem oslabení svalového vagu, který udržuje nízkou frekvenci.

## 3.5 Srdeční blokády

Vznikají v důsledku porušeného vedení vzruchu.

### 3.5.1 AV blokáda prvního stupně

Veškeré síňové vzruchy jsou převedeny na komory, avšak s dlouhým PR intervalem. Dochází k prodlužování PQ intervalů (viz. Obr. 3.4). Častým důvodem je zvýšený tonus vagu.

### First Degree AV Block



Obr. 3.4: AV blok prvního stupně, převzato z:[10]

### 3.5.2 AV blokáda druhého stupně


U blokády druhého stupně se převádí pouze některé vzruchy na komory. Například podle Wenkebachova intervalu (viz. Obr. 3.5). To znamená, že čas PR intervalu se stále prodlužuje až dojde k vynechání komorové odpovědi. Dále se AV blokáda druhého stupně může projevit opakovaným výpadkem QRS komplexu za P vlnou, tento typ blokády se označuje jako Mobitz II.[7]

### 3.5.3 Kompletní srdeční AV blokáda

Kompletní srdeční blokáda, tzv. blokáda třetího stupně, znamená, že šíření vzruchů mezi síněmi a komorami je úplně přerušeno (viz. Obr. 3.4). Rytmus vychází z komor a jedná se o idioventrikulární rytmus, který je nezávislý na síních. Bývá způsobena nodální bloádou AV uzlu, kde dojde k porušení vedení v oblasti AV uzlu. Novým pacemakerem se stává neporušená část AV uzlu, srdeční frekvence dosahuje 45 tepů za minutu. U infranodální blokády dojde k poškození Hisova svazku. Nový pacemaker vzniká v periferiích vodivé soustavy, srdeční frekvence bývá 20-35 stlačením za minutu. Příčinou blokády třetího stupně je infarkt myokardu, nebo poškození Hisova svazku.



Obr. 3.5: AV blokáda třetího stupně, převzato z:[10]



Obr. 3.6: AV blokáda druhého stupně, převzato z:[10]

### 3.5.4 Blokáda pravého nebo levého Tawarova raménka.

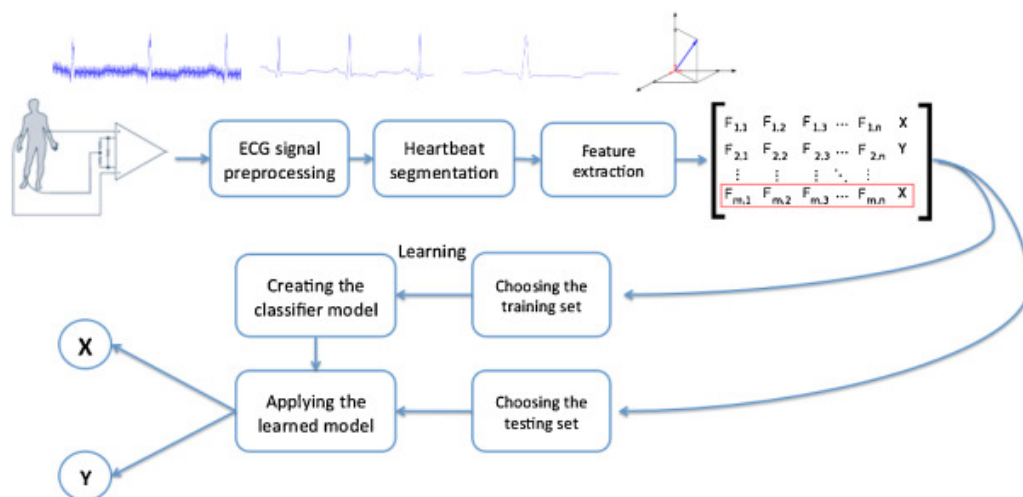
Tento typ blokády je způsoben přerušением vedení vzruchu za Hisovým svazkem. Vzruch se šíří nepoškozeným raménkem na myokard odpovídající komory a následně přechází na myokard komory, kterou mělo depolarizovat poškozené raménko.[7][11]

Spontánně se vzruchy v svalovině myokardu netvoří, protože frekvence z SA uzlu je vyšší. Při nesprávném fungování převodního systému můžou vzniknout ektopická ložiskové vzruchy. Jedná se o samovolné vzruchy o vyšší frekvenci, než je frekvence vycházející z SA uzlu. Dochází k předčasnému stahu, který naruší sinusový rytmus. Vybije-li se ložisko jednou, jedná se o extrasystolu, opakované vybíjení znamená tachykardii až flutter. [10][11]



## 4 Současné metody předzpracování signálu EKG

Detekce komorových extrasystol je procesem, kterému předchází předzpracování, segmentace, výběr příznaků a následná klasifikace(viz.Obr 4.1).[17]



Obr. 4.1: Postup detekce, převzato z: [17]

Většina studií se odkazuje na Asociaci pro rozvoj lékařských technologií (AAMI), která je zdrojem mezinárodních standardů pro zdravotnické technologie.[19] Podle AAMI rozdělujeme srdeční úder do pěti skupin: normální úder (N), supraventrikulární ektopický úder (S), komorový ektopický úder (V), sloučení komorového a normálního úderu (F) a úder, který neodpovídá těmto skupinám označujeme písmenem (Q). [25]. Tato práce je především předmětem klasifikace KES signálů a následně zobrazení patologických srdečních úderu.

### 4.1 Předzpracování


V EKG signálu se v určité míře vyskytují různé typy šumu(viz.Obr 4.2), které znehodnocují signál a znemožní kvalitní diagnostiku. Odrušením signálu rozumíme oddělení užitečné složky od nežádoucích složek signálu. Získané EKG bez šumu usnadňuje, ale také ovlivňuje, další zpracování. Pro detekci komorových extrasystol je nutné potlačit brum a drift.[20]

### 4.1.1 Typy rušení

**Rušení elektrického vedení** (brum) zatěžuje 50 Hz frekvenční složku, popřípadě 60 Hz a vyšší harmonické složky signálu. Síťový brum je způsoben:

- Nevhodným uzemněním měřicích elektrod EKG nebo pacienta.
- Odpojenou elektrodou.
- Elektromagnetickým rušením z elektrického vedení.
- V blízkosti se nachází elektrické zařízení s velkým výkonem, jako je rentgen indukující 50 Hz signál.

**Drift**, tzv. kolísání nulové izolinie, je nízkofrekvenční typ rušení zapříčiněn pomalými pohyby pacienta, elektrochemickými ději v místě dotyku kůže s elektrodou a nejčastěji dýcháním pacienta v průběhu měření. Frekvence driftu se pohybuje do 2 Hz. Pro detekci komorových arytmí je potřebná přesná nulová izolinie.[20] K signálu, který není zatížen žádným z šumů, jsem implementoval šумы pro demonstraci jejich vlivů na EKG signál. Výsledkem je příklad projevů jednotlivých šumů v EKG. Použil jsem signál z databáze PhysioNet.



Obr. 4.2: Demonstrace vlivu rušení na signál EKG.

## 4.1.2 Filtrace

Nejpoužívanější metodou filtrace je použití FIR a IIR filtrů. Zmíněné filtry lze aplikovat pro filtraci šumu o známé frekvenci (pásmová zadrž) jako je brum nebo pro odstranění vyšších/nížších frekvencí (horní/dolní propust). Dalším typem filtrů jsou adaptivní filtry, které jsou lehce implementovatelné a mohou být použity i pro segmentaci.[16][21] Podle studie[17] filtrování digitálním filtrem FIR nebo IIR je výhodnější než zmíněný adaptivní filtr.[17] Dle metody [22] byly signály filtrovány na základě dvou mediánových filtrů, k odstranění pohybu izolinie signálu. Metoda byla provedena tak, že signál byl filtrován dvěma mediánovými filtry s délkami oken 200 ms a 600 ms. Touto filtrací byla získána izolinie, která byla odečtena od původního signálu. Výsledkem je nová korigovaná nulová izolinie. Následně byl signál filtrován FIR filtrem typu dolní propust pro odstranění brumu a vysokofrekvenčního šumu. [22],[23],[25] Studie [22] uvádí, že EKG signál obsahuje nízkofrekvenční šum, a to vlivem dýchání a rušením elektrického vedení. Vysoké frekvence jsou obsaženy v brumu. Signál EKG je filtrován filtrem horní propust k odstranění nízkých frekvencí a následně filtrován filtrem pásmová zadrž pro odstranění brumu. Další možností je odstranění šumu pomocí vlnkové transformace, která zachovává vlastnosti signálu a odstraňuje nadbytečné prvky. Používá se i ke kompresi signálu.[27]

## 4.2 Segmentace a statistické termíny

Segmentace znamená oddělení důležitých struktur od pozadí a od sebe navzájem. [21] V EKG signálu se jedná se o detekci kmitu R nebo QRS komplexu.

### 4.2.1 Přesnost segmentace

Vyhodnocení klasifikace je dáno určením sensitivity, pozitivní prediktivity a přesnosti, které jsou definovány jako:[17]

$$Sensitivita = \frac{TP}{(TP + FN)} \quad (4.1)$$

$$Specificita = \frac{TN}{(TN + FP)} \quad (4.2)$$

Přesnost vyhodnocení vychází ze senzitivity a pozitivní prediktivity [26], dle vzorce:

$$accuracy = \frac{(TP + TN)}{(TP + FP + FN + TN)} \quad (4.3)$$

, kde TP – správná detekce; FP – detekce tam, kde neměla být; FN – detekce nebyla tam, kde měla být; TN – detekce nebyla, kde neměla být.[17]

### 4.2.2 Detekce R píku

Detekce komplexů QRS je nutná pro zpracování signálů EKG. Tvoří základ pro stanovení délek intervalů RR. Velice používaná je detekce založená na získání obálky filtrovaného signálu. Největší část energie je v pásmu 5 až 20 Hz. [9] Signál se umocní a tím zvýrazní komplex QRS, následně se signál vyhladí a projde dolní propustí s obdélníkovou impulsní charakteristikou. Následuje vytvoření obálky prostřednictvím nulování poloviny spektra signálu.[9]

Další možností je rozklad signálu bankou filtrů a to tak, že signál se rozdělí na segmenty s průměrnou velikostí QRS komplexů. Následně se stanoví práh pro detekci QRS. Pokud se v sousedních pásmech nachází nad prahové hodnoty nachází se v této lokalitě QRS komplex.

Signály z databáze ÚBMI obsahují anotaci jednotlivých signálů s detekovanými R kmity. Z tohoto důvodu se tato práce již více nezabývá problematikou detekce R kmitu.

### 4.2.3 Segmentace

Pro každý detekovaný R kmit je vytvořeno okno, pomocí kterého je vybrána část signálu obsahující celý QRS komplex a vlnu T. Vytvořený segment má konstantní délku a skládá se ze dvou částí. První část se skládá z úseku před kmitem R (pre-R úsek) a části po kmitu R (post-R úsek). V jednotlivých segmentech se nachází důležité prvky signálu a mohou být lépe porovnávány s ostatními segmenty.

## 5 Výběr příznaků ze signálu EKG

V této fázi hledáme v EKG signálu příznaky, které napovídají o přítomnosti KES. Výběr příznaků byl rozdělen do dvou skupin. Do první skupiny řadíme příznaky dle rozměření signálu. Druhá skupina obsahuje statistické metody, které reprezentují signál.

### 5.1 Metody pro hledání příznaků


Dle vybraných studií byly příznaky vybírány do následujících skupin: [22],[23][24][25]

#### 5.1.1 Skupina RR příznaků

Skupina RR příznaků se skládá z intervalů mezi úderů srdce. Jedná se o pre-RR interval (viz.Obr 5.1), tedy vzdálenost mezi aktuálním kmitem R a předchozím R kmitem. Post RR interval udává vzdálenost mezi aktuálním kmitem R a následujícím R kmitem. Dalším příznakem je průměrný RR interval celého záznamu. Lokální průměrný interval se skládá z tří až deseti po sobě jdoucích R kmitů. V počtu průměru RR se jednotlivé studie neshodují.

#### 5.1.2 Skupina intervalových příznaků.


Důležitými příznaky jsou také doby trvání vln nebo důležitých úseků signálu, odpovídající trvání depolarizace nebo repolarizace určité části srdce. Do této skupiny spadá především doba trvání QRS komplexu (QRS offset – QRS onset), doba trvání T vlny (T wave offset – QRS offset) a určení přítomnosti nebo nepřítomnosti P vlny(viz.Obr 5.1). V žádné ze studií nebyla P vlna rozměřována.



Obr. 5.1: Pozice QRS offset/onset, T wave offset, pre RR interval a post RR interval, převzato a upraveno z: [17]

### 5.1.3 Skupina morfologických příznaků.

Jedná se o skupinu, která se zaměřuje na získání amplitudových složek. Ve studii De Lannoy et al.[23] jsou získány obsahy pod křivkou vzhledem k nulové izolínii (viz. Obr 5.2). Hledáme pozitivní a negativní oblast P vlny, QRS komplexu a T vlny. Následně se autor zaměřuje na získání morfologických amplitud, kde získává 10 prvků pro reprezentaci P vlny a také QRS komplexu, devíti prvky reprezentuje T vlnu. Studie[22] využívá metodu interpolace, pomocí které bylo propojeno 18 vzorků ze segmentu jednoho srdečního cyklu (viz. Obr 5.2). Interpolace se používá k vytvoření časově závislých pozic na křivce[28]. Byly vytvořeny dvě vzorkovací okna na základě pozice kmitu R. První okno pokrývá QRS komplex a část signálu kolem. Druhé okno obsahuje T-vlnu. Okna byla přesně definována na základě vzdálenosti od detekovaného R kmitu. První okno se rozkládá na intervalu (-50 ms až + 100ms) a druhé okno, pro interpolaci T vlny je umístěno (+150 ms až +500 ms) od pozice kmitu R. V okně reprezentující QRS komplex je signál převzorkován na 60 Hz a dále na 20 Hz v okně následujícím.



Obr. 5.2: Morfologické znaky (vpravo) a interpolace EKG signálu, převzato a upraveno z: [17][25]

### 5.1.4 Zhodnocení

Metody založené na výběru příznaků prostřednictvím rozměření signálu dosahují průměrné přesnosti 89,85 %, dle [17]. Tyto studie byly vydávány kolem roku 2004. V současnosti je pro detekci komorových extrasystol využíváno statistických redukčních prvků nebo kombinace rozměření signálu a statistických redukčních prvků. Konvenční metody dosahují horší přesnosti klasifikace nejméně o 8 % ve srovnání se současnými metodami.

## 5.2 Statistické metody pro korekci množství příznaků

Jsou zde použité metody pro redukcí prvků, které snižují vstupní vektor příznaků a taktéž časovou náročnost klasifikace.[26]

### 5.2.1 Metoda PCA

Analýza hlavních komponent neboli Principal Component Analysis (PCA) je statistická metoda, která umožňuje popis skupiny lineárně závislých, popř. korelovaných příznaků. Jedná se o lineární transformaci originálních příznaků na nové nekorelované hlavní komponenty. Hlavní komponenta je dána svým vlastním číslem. Hlavní komponenty jsou na sobě nezávislé. Pokud mají znaky minimální rozdíl, nepřispívají k rozlišení mezi objekty. Nejvíce informací o rozptylu mezi daty obsahují první komponenty.[29] Hlavní komponenty nalézáme postupně, a to vytvořením vlastních čísel (viz. Eq: 5.4) a vektorů (viz. Eq: 5.7). První hlavní komponenta udává největší variabilitu. Následně se vytváří druhá hlavní komponenta, která udává zbytkový rozptyl, opět je nezávislá na předchozí komponentě. Tímto způsobem jsou nalezeny

další komponenty, které vytváří nezávislé kolmé vektory[30]. Metoda PCA je založena na hledání vlastních čísel ( $\lambda$ ) a vlastních vektorů ( $u$ ) z matice vztahů  $A$ . Tato matice  $A$  obsahuje vzdálenosti mezi jednotlivými objekty. Tato matice je vytvořená korelací, popřípadě kovariancí(viz. Eq: 5.1). Kovariance a korelace vyjadřují vzájemný vztah mezi daty. Pro kovarianci rozumíme vzájemnou závislost mezi veličinami  $X, Y$  (viz. Eq: 5.2). Vzorec pro kovarianci dvou veličin:

$$Cov(X, Y) = \frac{1}{(M-1)} \sum_{i=1}^M (x_i - \mu_x)(y_i - \mu_y), \quad (5.1)$$

kde  $M$  udává počet měřených objektů a  $\mu$  je střední hodnota dané veličiny. Sestavení matice vztahů  $A$  je dáno postupem, kdy příznaky seřadíme do sloupce a jednotlivé objekty do řádku. Následně odečteme střední hodnotu daného příznaku od všech objektů z tohoto příznaku. Kovarianční matice pro takto centrovaná data je spočtena, jako:

$$A = X^T X \quad (5.2)$$

Metoda PCA je založena na spektrálním rozkladu kovarianční matice  $A$  (viz. Eq: 5.3):

$$AV = \lambda V \quad (5.3)$$

Vlastní čísla  $\lambda$  určíme ze vztahu:

$$\det(A - \lambda I) = 0 \quad (5.4)$$

$$\det \begin{bmatrix} (a_{11} - \lambda) & a_{12} & a_{13} \\ a_{21} & (a_{22} - \lambda) & a_{23} \\ a_{31} & a_{32} & (a_{33} - \lambda) \end{bmatrix} = 0 \quad (5.5)$$

$$\det \left( \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix} - \begin{bmatrix} 1\lambda & 0\lambda & 0\lambda \\ 0\lambda & 1\lambda & 0\lambda \\ 0\lambda & 0\lambda & 1\lambda \end{bmatrix} \right) = 0 \quad (5.6)$$

V dalším kroku jsou vypočteny vlastní vektory z rovnice:

$$(A - \lambda I)V = 0, \quad (5.7)$$

kde  $V$  je matice vlastních vektorů,  $\lambda$  určuje matici vlastních čísel,  $I$  je jednotková matice. Rozkladem bylo dosaženo výpočtu vlastních vektorů:

$$\det \begin{bmatrix} (a_{11} - \lambda)v_{11} & a_{12}v_{21} & a_{13}v_{31} \\ a_{21}v_{12} & (a_{22} - \lambda)v_{22} & a_{23}v_{32} \\ a_{31}v_{13} & a_{32}v_{23} & (a_{33} - \lambda)v_{33} \end{bmatrix} \quad (5.8)$$

Hlavní komponenty jsou vypočteny ze vztahu (viz. Eq: 5.9):

$$P = XV, \quad (5.9)$$

kde  $X$  jsou původní data a  $V$  je již známá matice vlastních vektorů. [31]



## 5.2.2 Metoda ICA

Expres příznaků na základě analýzy nezávislých komponent (ICA) je metoda separace signálů, která odděluje nezávislé složky. Příkladem je problém: Coctail – party efekt, kde máme dva reproduktory a mikrofony, metodou ICA lze získat jednotlivé signály z reproduktorů. V kardiologii se tato metoda nejčastěji využívá pro detekci fetálního EKG. V tomto případě rozlišujeme EKG matky a plodu. Tato metoda se také používá pro výběr těch příznaků ze signálu, které jsou statisticky významné[32]. Metoda je definována vztahem:

$$x(t) = A * s(t), \quad (5.10)$$

kde  $x(t)$  odpovídá výslednému signálu s  $N$  prvky, signál  $s(t)$  je originální signál jako sloupcový vektor a  $A$  je směšovací matice (viz. Eq: 5.10). Jeden svod EKG signálu v ICA tvoří jeden řádek  $X$ . Počet  $N$  sloupců je dán počtem vzorků pro zpracování metodou ICA v jednom čase pro každý svod.[32],[33] Sloupce matice  $A$  jsou základní funkce, které zprostředkují pozorované signály. Inverzní matice k směšovací matici  $A$  je matice  $W$  (viz. Eq: 5.11), která transformuje signál do neznámého zdrojového koeficientu  $s$ .

$$s = W * x \quad (5.11)$$

Cílem ICA metody je najít základní funkce  $a_i$  z EKG dat (viz. Eq: 5.12). Základní funkce  $a_i$  jsou považovány za základní příznaky a komponenty signálu  $s$ ,  $s_i$  považujeme za koeficient pro každý základní příznak v poli příznaků. Model může být zapsán takto:

$$x = \sum_{i=1}^N s_i a_i \quad (5.12)$$

Segment z normálního EKG signálu o jedné  $R$  vlně může být reprezentován jako lineární superpozice z ICA základních funkcí  $a_1, \dots, a_N$  vztahovaných k odpovídajícím koeficientů  $s_1, \dots, s_N$ . Srdeční cyklus je nejčastěji reprezentován prvními 3 základními funkcemi, většina dalších je převážně nula. Základní funkce ICA odhalí statistické struktury z jednoho srdečního cyklu segmentu signálu EKG.

## 5.2.3 Vlnková transformace

Jedná se o rozšíření Fourierovy transformace (FT), FT je předmětem zkoumání pouze jednoho měřítka. Zatím co vlnová transformace je časově-frekvenční transformace, kde obě jsou reprezentovány měřítkem vlny. Touto metodou lze transformovat signál pomocí různých měřítek vln, pro zdůraznění různých detailů, například zkoumá velké a malé detaily.[26][31] Vlnová transformace je založena na posouvání a roztažení základní vlnkové funkce, která má nulovou střední hodnotu (viz. Eq:

5.13). Hledáme míru podobnosti mezi signálem a měnící se vlnkou. Výsledkem jsou vlnkové koeficienty  $w$ .

$$w(s, p) = \int_{-\infty}^{\infty} f(t) \frac{1}{\sqrt{s}} \overline{\psi\left(\frac{t-p}{s}\right)} dt \quad (5.13)$$

kde  $f(t)$  je analyzovaný signál;  $\psi$  odpovídá vlnce a je komplexně sdružená vlnka,  $s$  = měřítko a  $p$  je poloha na časové ose.

## 5.3 Klasifikace

Nejvíce používané klasifikátory pro účel detekce KES z EKG signálu jsou neuronové sítě (NN), metoda podpůrných vektorů (SVM) a lineární diskriminant.[26]

### 5.3.1 Lineární diskriminant

Diskriminační analýza je dána srovnáváním skupiny s nezávislými znaky tzv. srovnání diskriminátorů a výstupu. Na výstupu dostáváme skupiny, které jsou jasně odlišné a přiřazujeme do nich objekty. Cvičící data řadíme do skupin a tak vytváříme predikční model. Projekčním modelem myslíme diskriminační funkci, pomocí které můžeme zařazovat nové objekty do definovaných skupin.[26] Diskriminačních funkcí je stejný počet jako skupin na výstupu. Každému objektu je vypočítáno klasifikační skóre, následně objekt bude přiřazen do skupiny s největším skóre. [36]

### 5.3.2 Umělá neuronová síť

Neurony v centrální nervové soustavě vytváří složitou prostorovou síť. Biologický neuron se skládá z dendritů, těla neuronu, jádra a axonů. Neuron může přijmout signál a na tento impuls odpovědět nově vytvořeným signálem, který označujeme jako excitační postsynaptický potenciál (EPSP). Jeden EPSP je podprahový, což znamená, že sám není schopen vytvořit další vzruch. Podprahové signály se sčítají a při dosažení prahové hodnoty se vytvoří další vzruch. Vztahy mezi neurony jsou divergentní nebo konvergentní. Jeden divergentní vzruch vyvolává vzruchovou aktivitu pro několik neuronů. Konvergenční neuron přijímá vzruch z vícero neuronů. Nervové buňky následně tvoří složitou síť.[2]

Základním prvkem neuronové sítě je umělý neuron(viz. Eq: 5.14), matematicky jej vyjadřujeme jako:

$$y = F\left(\sum_{i=1}^n x_i w_i + b\right), \quad (5.14)$$

,kde máme  $n$  vstupů  $x_1, x_2, \dots, x_n$ , každý vstup je váhován váhami  $w_1, w_2, \dots, w_n$ . Písmenem  $b$  je označován práh

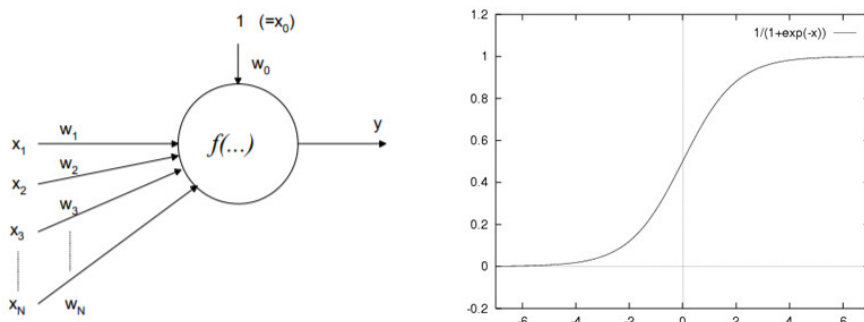
Neuron se skládá ze tří částí. Do vstupní části je přivedeno  $n$  vstupů, každý vstup je váhován váhami, které násobí vstupní hodnoty. Další částí je výkonná jednotka, která zpracovává informaci ze vstupu. Je-li celková informace větší než práh, výkonná jednotka zpracuje tuto vstupní informaci a pošle ji na výstup neuronu. Funkce  $F$  je v tomto případě funkce skoková (viz. Eq: 5.15), daná:

$$y = \begin{cases} 0 & \text{pro } \sum_i x_i w_i \leq b \\ 1 & \text{pro } \sum_i x_i w_i \geq b \end{cases} \quad (5.15)$$

První sloupec umělých neuronů zvažuje vstupní argumenty a podle velikosti celkové informace a velikosti prahů posílá do další vrstvy logické hodnoty 1 nebo 0 (viz. Obr 5.3). **Perceptron** tvoří neuronové sítě se schopností se učit tak, že malá změna váhy může způsobit změnu na výstupu. Perceptron má stejné grafické zobrazení jako neuron, ale jejich výstupní hodnota je v intervalu  $<0,1>$ . Sigmoidální funkce perceptronu  $F$  (viz. Eq: 5.16)(viz. Obr 5.3). je matematicky vyjádřena jako:

$$F(i) = \frac{1}{1 + e^{-z}} \quad (5.16)$$


Geometricky lze neuron interpretovat jako přímku rozdělující prostor na dva podprostory. Učení neuronu je proces určování správné pozice a natočení přímky.



Obr. 5.3: Model neuronu/ perceptronu (vpravo) a sigmoidální funkce perceptronu, převzato a upraveno z: [34],[35]

**Neuronová síť** se opět snaží, jako umělý neuron, napodobit lidský mozek. Neuronová struktura je rozdělena do vrstev (viz. Obr 5.4). První vrstva je vstupní s vstupními neurony, druhá až předposlední vrstva jsou tzv. vrstvy skryté. Poslední vrstva je výstupní, která udává konkrétní výstup.

V první vrstvě na definovaných vstupech proběhne výpočet dle (viz. Eq: 5.14). Neuron v  $(k)$  vrstvě je propojen se všemi neurony ve vrstvě následující  $(k+1)$ . Tedy následující vrstvy na vstupu využívají výstupní hodnoty předchozí vrstvy. Výsledek odpovídá výstupu v poslední vrstvě  $(k)$ .



Obr. 5.4: Dvouvrstvá perceptronová síť, převzato z: [34]

Posléze je vypočtena chyba na výstupu neuronu poslední vrstvy dle delta pravidla:

$$\delta = d - y, \quad (5.17)$$

kde  $d$  je očekávaná hodnota na výstupu a  $y$  je aktuální výstup.

Nyní vycházíme z předpokladu, že výstupní chyba (viz. Eq: 5.17) se v  $(k)$  vrstvě podle algoritmu zpětného šíření chyby rozdělí mezi neurony v  $(k-1)$  vrstvě v poměru vah. Metodou gradientního sestupu je síť optimalizována. Gradient  $E$  (viz. Eq: 5.18), který udává směr nejstrmějšího růstu chyby, je definován jako:

$$\text{grad}(E) = \frac{\partial E}{\partial w} = \frac{\partial E}{\partial y} \frac{\partial y}{\partial a} \frac{\partial a}{\partial w} = (y - d) * \frac{\partial f(a)}{\partial a} * x = -\delta * \frac{\partial f(a)}{\partial a} * x \quad (5.18)$$

kde derivace sigmoidní fce (viz. Eq: 5.19) odpovídá:

$$\frac{\partial y}{\partial a} = \frac{1}{T} * y(1 - y) \quad (5.19)$$

Optimalizace jednotlivých prahů a vah (viz. Eq: 5.20) probíhá s krokem učení  $\mu$

$$\begin{aligned} w_{\text{nové}} &= w_{\text{staré}} - \mu * \text{grad}(E) \\ b_{\text{nové}} &= b_{\text{staré}} - \mu * \text{grad}(E) \end{aligned} \quad (5.20)$$

Po dosazení gradientu (E) s konkrétním využitím sigmoidní funkce (viz. Eq: 5.21), dostáváme [34][35][36]

$$\begin{aligned} w_{\text{nove}} &= w_{\text{staré}} + \mu \delta \frac{1}{T} * y(1 - y) * \text{aktualni} - \text{vstup} \\ b_{\text{new}} &= b_{\text{old}} - \mu \delta \frac{1}{T} * y(1 - y) \end{aligned} \quad (5.21)$$

### 5.3.3 Metoda podpůrných vektorů


Metoda podpůrných vektorů (support vector machine - SVM). Jedná se o metodu, která hledá přímku pro rozdělení prostoru (viz. Obr 5.5) (viz. Eq: 5.22). Požadavkem pro nalezení přímky je ideální rozdělení prostoru objektů dle příznaků. Hraniční přímka je definovaná jako:

$$h(x) = \omega^T x_k + \omega_0, \quad (5.22)$$

kde  $\omega^T$  je orientace přímky a  $w_0$  je její poloha.  $X_k$  představuje k-tý vstup. Je nutno dodat, že ve 2D prostoru stanovujeme křivku, ve 3D prostoru rovinu. Máme vstup  $x$ , který bude zařazen dle dosažení do hraniční přímky  $h(x)$  (viz. Eq: 5.23).

$$skupina_1 = \text{pro } \omega^T x_k + \omega_0 > 0 \quad (5.23)$$

$$skupina_2 = \text{pro } \omega^T x_k + \omega_0 < 0$$



Obr. 5.5: Znázornění hraniční přímky a tolerančního pásma, převzato z: [36]

Nejllepší klasifikace bude dosaženo, pokud šířka tolerančního pásma ( $1/w$ ) bude co největší. Pro toleranční pásma platí  $\omega^T x_k + \omega_0 = \pm 1$ , proto zavádíme kritériální funkci  $J$  (viz. Eq: 5.24), pro niž platí:

$$J(w, w_0) = \frac{\|w\|^2}{2}; \text{ kde } \frac{2}{\|w\|} = \frac{1}{\|w\|} + \frac{1}{\|w\|}, \quad (5.24)$$

kde hodnota  $w$  je umocněna pro zjednodušení hledání minima.


Body ležící na hranici, tedy v tolerančním pásmu, nazýváme podpůrné body. Pokud se změní pozice těchto podpůrných bodů, změní se i hranice. Naopak změna ostatních bodů nevyvolá změnu hranice. Jedná se tedy o hledání minima funkce (5.24) za podmínky (5.23). [36]

### 5.3.4 Metoda k nejbližších sousedů

Algoritmus k-nejbližších sousedů (k-nearest neighbors; k-NN) je často využívanou metodou pro rozpoznávání vzorů (viz. Obr. 5.6). Metoda je neparametrického charakteru. [26] Metoda nejbližšího souseda je založena na výpočtu vzdálenosti mezi zařazovaným objektem a nejbližší vzdáleností objektu z klasifikačních skupin (viz. Eq: 5.25). Vztah lze zapsat jako:

$$D_{NN}(x, C) = \min_{x_q \in C} D(x, x_q), \quad (5.25)$$

kde  $D$  je metrika vzdáleností,  $C$  je množina subjektů a  $x$  je zařazovaný objekt. Pro



Obr. 5.6: k-NN;  $k=3$ , převzato z: [36]

každý subjekt je nalezeno  $k$  nejbližších prvků dle euklidovské vzdáleností. Subjekt je zařazen do skupiny, která odpovídá největší četnosti mezi vybranými  $k$  prvky. Počet  $k$  prvků je zpravidla liché číslo. [36]

## 6 Praktická část práce

Práce je realizována v programu Matlab 2017b.

### 6.1 Vstupní data a jejich předzpracování

K vytvoření algoritmu byla použita data z databáze ÚBMI. Jedná se o desetisekundové Holterovské záznamy. Konkrétně se jedná o standartní 12 - svodové EKG, kde jsou snímány svody II, III a šest hrudních svodů  $V_1 - V_6$ . Další svody mohou být dopočteny. Ve všech signálech je detekována globální pozice R kmitu. Data jsou anotována, respektive rozdělena do deseti skupin. Do první až páté skupiny jsou zařazeny signály dle rytmu: sinusový, supraventrikulární, komorový, nepravidelný rytmus způsobený fibrilací síní a ostatní. Následné skupiny jsou rozděleny dle blokády: AV blok, blokáda Tawarova raménka, komorové extrasystoly, ABSC (síňová tachykardie s aberantním převodem na komory), a signály s převládající šumovou složkou. Z databáze byla vybrána data se sinusovým rytmem bez blokády a následně data s komorovými extrasystolami.

Pro výběr dat je nutno splnit několik předpokladů:

- Výběr náležitých signálů bez patologií a s patologií KES.
- Trénovací a testovací množiny čítají přibližně stejný počet dat pro jednotlivé klasifikační skupiny.
- Trénovací množina dat se nepřekrývá s množinou testovací.
- V průběhu práce se množiny dat nemohou změnit.

Funkce ***vyberrhythmfinal.m*** vybere z množiny všech signálů potřebné signály a rozdělí je do skupin pro trénování a testování. Vstupem je anotovaná databáze ÚBMI a výstupem jsou potřebné signály. Z databáze ÚBMI byly vybrány signály s KES a taktéž normální (N) sinusové signály. Podmínkou pro přiřazení signálu do skupiny N je sinusový rytmus, bez patologií. Pro každý N signál byla provedena kontrola, zda je prvek zařazen ve skupině sinus a zároveň se nenachází ve skupině definované pro určitou patologii. Dále byly vybrány veškeré signály s KES. Takto byla získána množina dat pouzitelnesignaly.mat, která může být použita v dalším zpracování. V této množině se nachází 413 signálů s KES a 3212 N signálů.


Nyní uvažujeme pouze skupinu s KES signály. Každý osmý signál slouží pro testování. Tohoto je dosaženo na základě výpočtu zbytků po dělení. Ze skupiny signálů s KES bylo vybráno 51 signálů pro testování a 362 pro trénování. Následně obě množiny s KES (trénovací + testovací) byly rozšířeny na dvojnásob o tyto samé prvky. Tímto rozšířením bylo získáno 724 signálů pro trénování. Množina všech rozšířených trénovacích dat odpovídá množině dat trénovacích bez rozšíření. N signály nebyly rozšířeny, pouze bylo vybráno 826 signálů.

Výstupem je množina dat ve formě buňkového pole, kde v prvním řádku se nachází signály N pro trénování a v řádku druhém signálu odpovídající detekované pozice R kmitů. Trénovací signály KES byly zařazeny do třetího řádku, opět v řádku následujícím se nachází R kmity. Stejným způsobem je uspořádána množina dat pro testování.

Následná funkce *konkretnisignal.m* dle požadavků vybere odpovídající signál na základě vstupu( odpovídající množina: trénovací/testovací, pořadí signálu, svod). Odpovídající data jsou převedena do formátu pole. V jednotlivých sloupcích jsou uloženy data z měřených svodů. Výstupem funkce je konkrétní signál, vzorkovací frekvence, časová složka signálu a kmitočet.

### 6.1.1 Předzpracování

Součástí této práce je vytvoření 4 filtrů obvykle užívaných pro filtraci EKG(viz.filtrý-teoretická část). První filtr se soustředil na odstranění driftu. Pomocí dvou mediánových filtrů o délce oken 200 ms a 600 ms byla získána izolinie. Následně je tato získaná izolinie odečtena od originálního signálu. Tímto postupem je dosaženo nulové izolinie. Posléze byl vytvořen filtr potlačující 50 Hz složku signálu. Třetím filtrem byl filtr dolní propust s mezní frekvencí 80 Hz. Cílem bylo odstranit vysokofrekvenční šum. Byl použitý nerekursivní filtr FIR s lineární fázovou charakteristikou. Následně byl využitý filtr vlnkové transformace z MATLAB: Wavalet Toolbox- Wavelet Signal Denoiser, pro redukci šumu.



Obr. 6.1: Filtrace signálu

Veškeré realizované filtry byly uplatněny pro detekci využívající PCA – SVM nebo PCA – ANN klasifikátor. Je nutno podotknout, že uvedené výsledky neodpo-



vídají výsledným klasifikátorům. Dílčím cílem realizace práce bylo určení nejefektivnější filtrace. Výsledná data dobře reprezentují využití typu filtrů.

<i><b>Hledání optimální filtrace</b></i>				
	<i>ACC [%]</i>	<i>SE [%]</i>	<i>SP [%]</i>	<i>t [s]</i>
<i>bez filtrace</i>	39,73	97,82	24,58	21,77
<i>1.-filtr na drift</i>	90,33	81,36	92,66	11,97
<i>2.-vlnková filtrace</i>	39,83	98,06	24,67	23,95
<i>3.-DP 80 Hz; FIR</i>	31,55	98,55	13,94	16,89
<i>4.-PZ 50 Hz; IIR</i>	39,55	98,07	24,33	90,21
<i>1.+2.</i>	90,45	81,12	92,88	12,61
<i>1.+4.</i>	90,38	81,12	92,79	33,79
<i>1.+2.+4.</i>	90,60	81,72	92,92	46,85

Tab. 6.1: Hledání optimální filtrace

Bylo zjištěno, že klasifikace bez použití filtrace je velice neefektivní. Dosažená průměrná přesnost pro klasifikátory je 39,8 %. Vytvořený program zpracoval 2 000 signálů za dobu 21,77 s. Pro další zpracování budeme tyto hodnoty považovat za výchozí. Filtrací brumu došlo k nepatrnému zlepšení klasifikace časové náročnosti (+1,37 s). Filtrací driftu bylo dosaženo přesnosti 90,4 % s časem 23,95 s (+1,68 s). Vlnová transformace opět dosáhla nepatrného zlepšení, ovšem s časem  $t = 90,21$  s (+47,23 s). Filtrací dolní propustí byla zhoršena přesnost klasifikace. Na základě časové náročnosti a účinnosti filtrace již neuvažujeme použití filtrů DP a vlnkové filtrace. Pro řešení této problematiky je vhodné použít filtr pro filtraci driftu nebo použití tohoto filtru v kombinaci s IIR filtrem na 50 Hz. (viz.Tab 6.1) Na základě výsledků a zkoumání dat z databáze ÚBMI stačí odstranění driftu. Pro jiná data by bylo preventivně použito i filtru pro odstranění brumu.

## 6.1.2 Normalizace příznaků

Veškeré nalezené příznaky, kromě příznaků s nulovou hodnotou, vstupují do funkce normalizace. Vstupy jsou nalezené příznaky s odkazem na metodu výběrů příznaků (skupina). Každý výběr příznaků má skupinu, ve které jsou informace v podobě střední hodnoty konkrétního příznaku a směrodatné odchylky příznaku. Normalizace dat je proces, při kterém dochází ke změně měřítka dat za účelem snadnějšího porovnání. Tento krok je velice důležitý. Příznaky s větší vstupní hodnotou, nebo větší směrodatnou odchylkou mají větší význam při klasifikaci. Pro normalizaci byla

použita nejběžnější standardizační Z funkce (viz.Eq 6.1). Nové normalizované příznaky se nachází v intervalu  $\langle -2,2 \rangle$ , kde střední hodnota příznaku (viz.Eq 6.2) pro učení je 0 a směrodatná odchylka(viz.Eq 6.3) je 1. Tyto hodnoty se pro testovací data mohou nepatrně měnit.

$$Z funkce : z_{i,j} = \frac{x_{p,o} - \mu_p}{\sigma_p} \quad (6.1)$$

kde  $x_{o,p}$  je příznak p z objektu o, dále:

Střední hodnota konkrétního příznaku:


$$\mu_p = \frac{\sum_{o=1}^N x_{o,p}}{N} \quad (6.2)$$

Směrodatná odchylka příznaku:

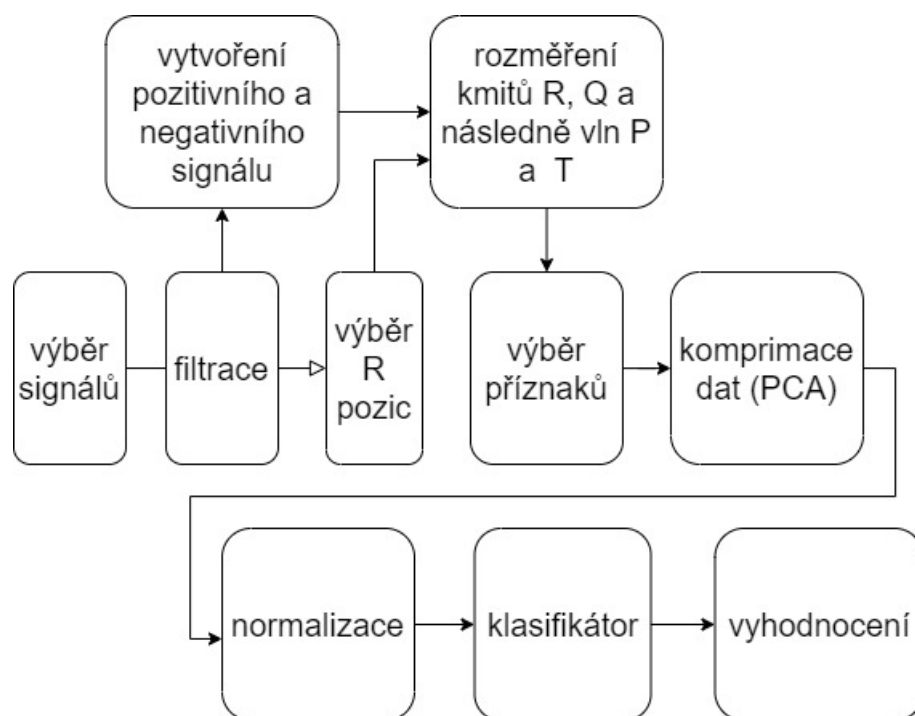
$$\sigma_p = \sqrt{\frac{\sum_{o=1}^N (x_{o,p} - \mu_{o,p})^2}{N - 1}} \quad (6.3)$$

## 6.2 Metoda přibližného rozměření

Metoda je založená na hledání amplitud, obsahů, trvání vybraných vln a kmitů. Rozměření signálu vycházelo ze studie [37], kde rozměření vychází z poznatku, že obsah QRS komplexu je součet jednotlivých kmitů Q, R, S. Metoda je doplněna o znalosti (viz. kapitola 5). Blokové schéma metody je znázorněno na (viz.Obr. 6.3).




Obr. 6.2: Rozměření signálu, převzato z: [37]



Obr. 6.3: Blokové schéma metody přibližného rozměření


Problémem řešení je, že nulová izolinie reálného signálu, neodpovídá vzorové izolinii (viz.Obr 6.2). V rámci této práce a ve snaze rozměřit signál bylo zjištěno, že mediánovou filtrací s délkou okna 300 ms dojde k vytvoření nové křivky. Získaná křivka protíná P, T vlnu, QRS komplex v jeho počátcích a rovněž koncích(viz.Obr 6.4).



Obr. 6.4: Křivka vzniklá mediánovou filtrací


Nyní budou z jednoho signálu vytvořeny dva nové signály. Pro první signál platí, že křivku + parazitní šum, vzniklý mediánovou filtrací, proložíme nulou, taktéž

hodnoty pod křivkou jsou nula (pozitivní signál). Tento krok byl proveden i pro získání negativních kmitů proložení křivky a vyšších hodnot nulou (negativní signál). Tímto způsobem došlo k vytvoření dvou následujících signálů. (viz.Obr 6.5)




Obr. 6.5: Pozitivní a negativní signál

Následným krokem je nutno specifikovat, jakým způsobem se bude pracovat se signálem. Pro tuto specifikaci bude uvažován originální signál. Byly vybrány 3 segmenty reprezentující KES a N úder. Jedná se o dva projevy KES a jeden N, z důvodu rozdílnosti projevu KES (viz.KES). Pomocí barevného označení byly definovány oblasti, kde budou hledány maxima nebo minima daných kmitů(viz.Obr 6.6). Tmavě modrá barva označuje oblast hledání maxima/minima pro P vlnu. Červeně vymezené okno se odkazuje na oblast R kmitu, kyanově značená zóna se soustředí na Q vlnu a černě vyznačená oblast hledá maximum vlny T.




Obr. 6.6: Hledání pozic maxima/minima jednotlivých kmitů

Červená oblast R je dlouhá 0,08 s, kde střed je v detekovaném kmitu R. Tmavě modrá oblast P-vlny je dlouhá 0,18 s a černé okno okolo T vlny je dlouhé 0,2 s. Vzdálenost mezi červeným a černým T oknem je 0,08 s, délka od tmavě modré P oblasti k červenému oknu je 0,06 s. Q oblast je dlouhá 0,04 s se vzdáleností od detekované R kmitu 0,02 s. V červeně vyznačeném okně pro R vlnu je hledána maximální výchylka a absolutní hodnota minimální amplitudy. Větší hodnota je zapsána jako amplituda. Jestliže je vybráno maximum, dále pracujeme s pozitivním signálem v opačném případě je vybrán negativní signál. Od pozice vybraného maxima/minima, probíhá cyklus while s krokem posunutí polohy o  $\pm 0,0002$  s. Podmínkou ukončení cyklu je dosažení amplitudy rovnající se nule nebo záporné/ kladné hodnotě. Cyklus zapisuje hodnoty amplitud, prvně pravé strany a následně strany levé od maxima. Pro každý R kmit hodnotíme již dříve zmíněnou amplitudu, délku R kmitu (počet kroků cyklu) a obsah (součet amplitud pod křivkou v rámci cyklu). Tato funkce (delkynove2.m) určí amplitudy, délky a obsahy: vln P, vln T a kmitů R. Následně jsou přibližně odměřeny obsahy Q kmitů a to tak, že v daném poli (vyznačeno kyanově) jsou vzaty všechny amplitudy. Pro každý signál je počítáno s 20 R kmity. Signály s menším počtem R kmitů jsou doplněny nulami a ve výjimečně se vyskytujících signálech s více než 20 R kmity je počítáno pouze s prvními dvaceti. Jedná se o vícerozměrnou úlohu, z tohoto důvodu byla zavedena redukce dat pomocí analýzy hlavních komponent pro každou z typů vln EKG signálu. Výstupem funkce jsou čtyři hlavní komponenty, reprezentující vlnu P, R, T a oblast Q. K čtyřem hlavním komponentám jsou připojeny další čtyři hlavní komponenty z příznaků: (RR intervaly, korelace segmentů s reprezentativním N segmentem, amplitudy R kmitů, a průměrnými amplitodami v oblastí R kmitů). O těchto příznacích je pojednáno v částí konvenční metody. Vstupem do klasifikátoru je osm příznaků pro rozměření jednoho svodu, konkrétně svodu II. Dále jsou využity svody V1 a V6. Z těchto svodů je získáno šestnáct příznaků, tedy 3x4 hlavní komponenty z rozměření a následně čtyři hlavní komponenty z intervalových rozměření pouze ze svodu II.



Obr. 6.7: Přibližné rozměření N signálu



Obr. 6.8: Přibližné rozměření KES signálu

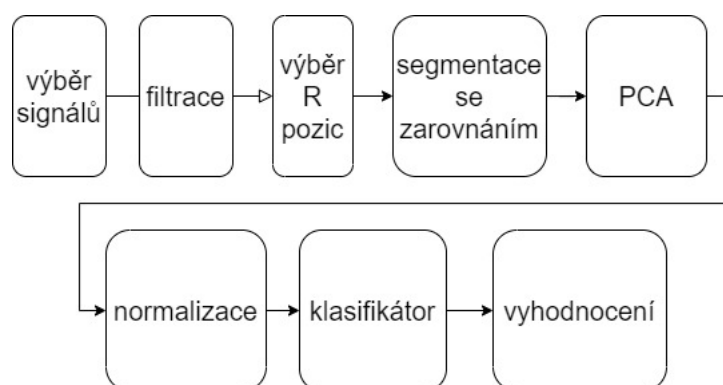
Nejvíce používaným klasifikátorem je dopředná neuronová síť. Struktura neuronové sítě je značena číslicemi oddělenými pomlčkami např (13-3-1). První číslice udává počet perceptronů ve vstupní vrstvě, zde 13. Poslední číslice je zpravidla 1, kde tento výstupní neuron udává konkrétní výstup  $0 = N$ ,  $1 = KES$ . Počet cifer mezi těmito krajními hodnotami udává počet skrytých vrstev a opět hodnota číslice odpovídá počtu perceptronů v konkrétní vrstvě.

Příznaky: Přibližné rozměření; klasifikátor: dopředná neuronová síť							
neurony	4-1	8-1	12-1	16-1	24-1	32-1	50-1
ACC[%]	94,6	93,2	93,7	92,2	94,1	93,2	90,7
SE[%]	94,1	90,2	94,1	90,2	90,2	92,2	100
SP[%]	95,1	96,1	93,2	94,2	98,1	94,2	81,6
PPV[%]	95	95,8	93,2	93,9	97,9	94,0	84,3
F1[%]	94,6	92,9	93,7	92	93,9	93,1	91,5

Tab. 6.2: Příznaky: přibližné rozměření; klasifikátor: Dopředná neuronová síť

## 6.3 Metoda s využití PCA

Kromě úprav zmíněných v sekci (viz.kapitola 6.1), je nutno znát pozice detekovaných R kmitů. Potom jsou pozice R kmitů použity pro segmentaci, zde konkrétně *segmentace.m* (viz.kapitola 4.2.3). Blokové schéma metody je vykresleno (viz.Obr. 6.9).




Obr. 6.9: Blokové schéma metody PCA zarovnaných segmentů

Vstupem do funkce je množina vybraných signálů (signals), pořadí konkrétního signálu v množině, svod, vzorkovací kmitočet a pozice detekovaných R kmitů. Výstup funkce zahrnuje veškeré segmenty a novou časová x-složka segmentu (viz.Obr 6.10). V prvním kroku je zjištěno, kolik R kmitů se nachází v signálu. Tato četnost kmitů je rovna množství výsledných segmentů. Pro vytváření segmentů byly definovány dvě podmínky:

- Souhrnně: Konkrétní segment nesmí přesahovat původní signál.
- Vzdálenost mezi detekovaným R a koncem signálu musí být větší než 0,504 s (délka druhé části segmentu + možný posun).

- Vzdálenost mezi detekovaným R a počátkem signálu musí být větší než 0,122 s (délka první části segmentu).

Pro vytvoření konkrétního segmentu musí obě podmínky platit současně. Pokud podmínka není splněna, konkrétní kmit je nahrazen jiným segmentem, kde je podmínka splněna. V dalším kroku je nalezena maximální/ minimální amplituda R kmitu. Tento bod je považován za výchozí amplitudu R, jelikož detekce R kmitu neurčuje maximální amplitudu kmitu R, ale vlnu R. Z tohoto důvodu vznikne posun oproti původní detekci. Segmentační podmínky musí být rozšířeny o možný posun vzniklý upřesněním pozice R kmitů, který je v rozmezí  $\max(-0,06s - 0,1s)$ . Tímto dojde k zarovnání signálu. Délka segmentů je konstantní a to 0,46 s. Veškeré segmenty R kmitů tvoří výstup této funkce.




Obr. 6.10: Segmentace signálu

Vektor  $x_2$  je časová složka signálu, je vypočten jako vektor od 1 do délky vektoru vynásoben vzorkovacím kmitočtem.

Funkce PCA pracuje s již dříve získanými segmenty. Bylo využito funkce prostřednictvím programu Matlab (pca). Princip a využití metody PCA (viz.PCA-teoretická část) je popsán v teoretické části, proto se zde již více nebude rozebírat postup výpočtu. Bylo zjištěno, že již čtyři hlavní komponenty reprezentují signál s více než 90 % (viz.Obr 6.10).





Obr. 6.11: Míra reprezentativnosti podle hlavních komponent

Tato metoda byla realizována pro svod II (viz.Tab 6.3) a svody (II, V1 a V6)(viz.Tab 6.43). V prvním případě do klasifikátoru vstupují 4 příznaky a v druhé realizaci do-  
dáváme na vstup 12 příznaků. Jako klasifikátor je zde použita dopředná neuronová  
sít (viz.Tab 6.3 a Tab 6.4), SVM a KNN (viz.Tab 6.5).

Příznaky: metoda PCA (II svod); klasifikátor: Dopředná neuronová síť								
neurony	1-1	2-1	4-1	5-1	6-1	8-1	9-1	15-1
ACC[%]	98,05	97,32	98,05	96,59	95,61	97,07	97,07	97,07
SE[%]	100	100	100	100	100	100	100	98,04
SP[%]	96,12	94,17	96,12	93,20	91,26	94,17	94,17	96,12
PPV[%]	96,23	94,44	96,23	93,58	91,89	94,44	94,44	96,15
F1[%]	98,08	97,14	98,08	96,68	95,77	97,14	97,14	97,09

Tab. 6.3: Hledání optimalní struktury neuronové sítě, pro metodu PCA (II svod)

Příznaky: metoda PCA (svody II, V1 a V6); klasifikátor: Dopředná neuronová síť								
neurony	1-1	3-1	6-1	10-1	12-1	14-1	20-1	24-1
ACC[%]	97,1	98	98	98	97,6	98	95,1	97,1
SE[%]	100	100	100	100	100	100	98	98
SP[%]	94,2	96,1	96,1	96,1	95,1	96,1	92,2	96,1
PPV[%]	94,4	96,2	96,2	96,2	95,3	96,2	92,6	93,2
F1[%]	97,1	98,1	98,1	98,1	97,6	98,1	95,2	97,1

Tab. 6.4: Hledání optimalní struktury neuronové sítě, pro metodu PCA (II, V1, V6 svod)

Hledání optimálního k počtu sousedů; klasifikátor KNN							
Svod: II				Svody: II, V1 a V6			
k- sousedů	ACC[%]	SE[%]	SP[%]	k- sousedů	ACC[%]	SE[%]	SP[%]
100	84,9	82,4	87,4	100	92,7	90,2	95,1
21	94,6	98	91,3	3	97,1	98	92,2
100	96,1	98	94,2	30	93,7	90,2	95,1
61	97,1	100	94,2	111	92,2	86,3	98,1
215	95,1	94,1	96,1				

Tab. 6.5: Hledání optimálního k počtu sousedů- metoda PCA; klasifikátor KNN

Metoda založená na PCA se zarovnanými segmenty je vyhodnocena neuronovou sítí a dosahuje pro svod II přesnosti ACC = 98 %, senzitivity SE = 100 % a specificity SP = 96,12 %. Následně klasifikátor KNN s nastavením ( $k = 165$ ) docílil přesnosti ACC = 97,1 %, senzitivity SE = 98 % a specificity SP = 96,1 %. Přesnost klasifikátoru SVM docílila ACC = 90,7 %, senzitivity SE = 84,3 % a specificity SP = 96,1 %. Získané příznaky ze svodů II, V1 a V6 s NN klasifikací dosahují stejné přesnosti jako NN klasifikátor pro svod II. Klasifikátor KNN s ( $k = 3$ ) dosahuje přesnosti ACC = 96,6 %, senzitivity SE = 96,1 % a specificity SP = 97,1 %. Klasifikátor SVM dosáhl přesnosti ACC = 89,3 %, senzitivity SE = 82,4 % a specificity SP = 97,1 %.

## 6.4 Metoda dle starších studií

Tento způsob výběru příznaků vychází ze studií [22],[23][24][25].(viz.kapitola 5). Blokové schéma je popsáno (viz.Obr.6.12).



Obr. 6.12: Blokové schéma metody dle starších studií

Filtrovaný signál byl opět segmentován použitím segmentace bez zarovnání. Z každého segmentu byly vybrány příznaky: amplituda R kmitů, amplituda T vln a průměry signálů v okně dlouhém 0,1 s se středem v kmitu R. Následně byly vybrány příznaky intervalové pre – RR interval, post – RR interval a průměry 3 RR intervalů. Poslední dva příznaky tvořila křížová cross korelace segmentu a reprezentativního průměru N segmentu. Další příznak tvoří hlavní komponenta ze segmentu a reprezentativního průměru N segmentu. Tyto příznaky byly získány ze všech segmentů a seřazeny do sloupce. Metoda počítá s dvaceti segmenty, kde kratší signály jsou doplněny nulami. Výstupu funkce obsahuje 160 příznaků + průměr 10-ti RR intervalů. Tyto příznaky vstupují do dopředné neuronové sítě. Očekávaný výsledek přesnosti klasifikace dle studie [17] je  $ACC = 89,85 \%$ . Touto realizací bylo dosaženo přesnost  $ACC = 92,2\%$ , senzitivity  $SE = 0,2\%$  a specifity  $SP = 94,2 \%$ . (viz.Tab 6.6) Nepatrné zlepšení může být důsledkem přidání příznaků korelace a taktéž kombinací příznaků z několika studií.

Příznaky: RR- intervaly, amplitudy, korelace, klas.: NN				
neurony	ACC [%]	==>	N	ACC [%]
30-1	84		50	88,9
60-1	87,5		60	90
100-1	86,75		70	90,7
161-1	out of mem.		80	92,55
Podmínky:			90-1	88,25
SE>80%;SP>80%			100-1	90,85
			110-1	85,75

Tab. 6.6: Metody dle starších studií; Příznaky: RR- intervaly, amplitudy, korelace, klasifikátor: NN

## 6.5 Kombinace příznaků

Kombinací příznaků z metody PCA a přibližného rozměření + intervalových příznaku z předchozí metody bylo dosaženo přesnosti klasifikace ACC = 97,1 %, senzitivity SE = 98% a specificity SP = 96,1 % (viz.Tab 6.7).

Příznaky: Přibližné rozměření + PCA metoda; klasifikátor: Dopředná neuronová síť										
neurony	4-1	8-1	16-1	28-1	32-1	50-1	8-3-1	13-3-1	28-3-1	28-1-1
ACC [%]	96,6	95,1	96,1	97,1	97,1	95,1	96,6	97,1	96,1	95,1
SE[%]	96,1	96,1	96,1	98	98	96,1	96,1	98	98	96,1
SP[%]	97,1	94,2	96,1	96,1	96,1	94,2	97,1	96,1	94,2	94,2
PPV[%]	97	94,2	96,1	96,2	96,2	94,2	97	96,2	94,3	94,2
F1[%]	96,6	95,1	96,1	97,1	97,1	95,1	96,6	97,1	96,2	95,1

Tab. 6.7: Příznaky: Přibližné rozměření + PCA metoda; klasifikátor: Dopředná neuronová síť

## 6.6 Rozpoznání KES a BBB

Raménkové blokády (bundle branch block – BBB) jsou srdeční blokády, které se často vyskytují při plicní embolii nebo vrozenou vadou. Při bloádě pravého Tawarova raménka (RBBB) je QRS komplex široký > 0,12 s. V pravokomorovém svodu (V1) je QRS komplex ve tvaru M a v levokomorovém svodu (V1) se nachází široký kmit S. Blokáda levého Tawarova raménka (LBBB) se ve svodu V6 projevuje malým

Q kmitem s následným velkým R kmitem. V levokomorovém svodu (V6) dochází k širokému rozštěpenému QRS komplexu. V ostatních svodech je široký QRS komplex  $> 0,12$  s. Komorové extrasystoly byly podrobně již popsány (viz.Text- KES).

Příznaky: Přibližné rozměření signálu + metoda PCA; klasifikátor: NN								
neurony	10-3-3	13-3-3	16-3-3	20-3-3	24-3-3	28-3-3	35-3-3	50-3-3
N-ACC[%]	92,13	92,81	91,5	94,12	93,7	93,79	93,5	95,1
KES-ACC[%]	-	83,32	-	58,97	86,35	85,95	83,64	82,67
BBB-ACC[%]	-	-	67,68	76,48	77,82	79,41	78,74	80,05
neurony	4-3	8-3	16-3	20-3	30-3	PODMÍNKY:		
N-ACC[%]	93,4	93,4	93,14	92,48	80,94	N: SE>90%;SP>80%		
KES-ACC[%]	84,16	85,57	86,16	86,31	47,05	KES: SE>80%;SP>80%		
BBB-ACC[%]	75,01	75,23	71,76	68	36,44	BBB: SE>70%		

## 7 Výsledky

Realizací navržených detektorů se ukázalo, že nejlepších výsledků pro určení KES bylo dosaženo metodou PCA zarovnaných segmentů s klasifikátorem: dopředná neuronová síť. Tímto provedením bylo dosaženo přesností  $ACC = 98,5 \%$ , senzitivity  $SE = 100 \%$  a specifcity  $SP = 96,1 \%$ . Použitím klasifikátoru KNN pro stejnou metodu vedlo k výsledné přesnosti  $ACC = 97,1 \%$ , senzitivity  $SE = 100 \%$  a specifcity  $SP = 94,2 \%$ . Metoda přibližného rozměření s klasifikátorem dopředná neuronová síť dosahuje přesnosti  $ACC = 94,6 \%$ , senzitivity  $SE = 96,1\%$  a specifcity  $SP = 93,2 \%$ . Další metoda založena na starších studiích dosahuje přesností  $ACC = 92,2 \%$ , senzitivity  $SE = 90,2 \%$  a specifcity  $SP = 94,2 \%$ . Kombinací těchto metod pro výběr příznaků, bylo dosaženo přesnosti  $ACC = 97,1 \%$ , senzitivity  $SE = 98\%$  a specifcity  $SP = 96,1 \%$ . (viz.Tab.- Vyhodnocení klasifikace KES)

Úspěšnost metod pro klasifikaci N a KES				
metoda	ACC[%]	SE[%]	SP[%]	F1[%]
NN: PCA; svod: II	98,05	100	96,1	98,1
NN: PCA; svody: II, V1 a V6	98,05	100	96,1	98,1
NN: Přibližné rozměření + PCA; svody: II, V1 a V6	97,1	98	96,1	97,1
KNN: PCA; svod II	97,1	100	94,2	97,1
KNN: PCA; svody: II, V1 a V6	95,1	98	92,2	95,2
NN: Přibližné rozměření	94,6	96,1	93,2	94,7
NN: RR intervaly, amplitudy + korelace; svod II	92,2	90,2	94,2	92
SVM: PCA; svody: II, V1 a V6	90,7	84,3	96,1	90,1
SVM: PCA; svod II	89,3	82,4	97,1	88,4

Tab. 7.1: Vyhodnocení klasifikace KES


Následně byl vytvořen detektor pro detekci blokády Tawarova raménka, KES a N signálů. Přesnost klasifikace BBB je  $ACC = 79,4 \%$ , přesnost určení KES je  $ACC = 85,6 \%$  a N přesnost  $ACC = 93,8 \%$ . (viz.Tab.- Vyhodnocení klasifikace BBB, KES a N)

<b>Klasifikace N, BBB a KES</b>				
NN: Přibližné rozměření signálu + PCA	ACC[%]	SE[%]	SP[%]	F1[%]
N signál	93,8	90,2	95,6	90,6
signál s KES	85,6	82,4	87,3	79,2
signál s BBB	79,4	80,4	78,9	72,2

Tab. 7.2: Vyhodnocení klasifikace BBB, KES a N

## 8 Diskuze

Dle získaných výsledků je jednoznačné, že nejlepší výsledky byly dosaženy metodou PCA zarovnaných segmentů. Zmíněná metoda dosahuje přesnosti  $ACC = 98,05 \%$  a senzitivity  $SE = 100 \%$  pro určení KES. Následná metoda přibližného rozměření dosahuje přesnosti  $ACC = 97,1 \%$  a senzitivity  $SE = 98 \%$ . Metoda dle starších studií docílila přesnosti  $ACC = 92,2 \%$  a senzitivity  $SE = 90,2 \%$ . Graf porovnávající jednotlivé metody výběru příznaků (viz. Obr. 8.1), ukazuje chybovost na testovacích signálech (205). Osa x popisuje posloupnost testovacích signálů, kde prvních 102 signálu reprezentuje KES signály. Osa y určuje přiřazení, 0 = určení N signálů naopak 1 = přidělení KES signálů. Pokud se v klasifikaci vyskytne chyba pozorujeme strmý pík k opačnému znaménku. V ideálním případě se v první části, která je oddělena černou linkou, vyskytnou pouze 1 a v druhé části 0. U všech metod je pro srovnání použita klasifikace dopřednou neuronovou sítí.



Obr. 8.1: Srovnání metod

Značnou výhodou metody PCA zarovnaných segmentů je úplné určení všech signálů s KES ( $SE = 100 \%$ ). Tato metoda čítá 2 špatně zařazené signály. Chybovost se vyskytla pouze při detekci N signálů. Po důkladném průzkumu chybně zařazených signálů bylo zjištěno, že se jedná především o signály s negativním R kitem, které by ovšem ve svodu II neměly být přítomny.


Další metoda Přibližné rozměření špatně klasifikovala 10 signálů. Čtyři chyby se vyskytly v určení KES a následně 6 chyb při detekci N, kde 33 % chybovosti bylo shodné s chybovostí metody PCA. Zde se jedná o signály s negativním kitem R ve svodu II a signály s výraznou šumovou složkou. Zvolený postup výběru příznaků není vhodný pro použití na signálech s výraznou šumovou složkou. Šum může



ve velké míře zkreslit výsledky a zároveň umožní detektoru předčasně detekovat počátek nebo konec některého z kmitů. Výhodou je vysoký počet příznaků, tedy informace o konkrétním signálu. Tato metoda by byla vhodná i pro klasifikaci signálů do více skupin. Dalším přínosem je jednoduchá interpretace této metody, respektive metoda je založena na přibližném rozměření délek, amplitud a obsahu pod křivkou jednotlivých kmitů.

Metoda sestavena na základě starších studií dosahuje 13 chyb. Množství chyb v určení KES je 10 a 3 v určení N signálů. Značnou nevýhodou této metody je nízká senzitivita  $SE = 90,2 \%$ . Není zde žádná korelace mezi chybovostí této metody s výše uvedenými. Tato metoda cílí na rozměření RR intervalu, z tohoto důvodu by proto byla vhodnější pro určení tachykardií nebo flutteru komor.

Následně graf porovnávající jednotlivé klasifikátory (viz.Obr 8.2), naznačuje chybovost jednotlivých klasifikátorů metody výběrů příznaků.



Obr. 8.2: Srovnání klasifikátorů

V práci bylo pracováno se třemi typy klasifikátorů: dopředná neuronová síť, SVM a KNN.

Na základě výsledků se ukázalo, že za daných podmínek neoptimálnějším klasifikátorem pro detekci KES je dopředná neuronová síť. Na výstupu byly detekovány pouze 4 chyby v určení N signálů. Dopředná neuronová síť byla rovněž často použita jako klasifikátor v mnoha současných studiích zaměřených na tuto problematiku.


Klasifikátor KNN s využitím pouze svodu II dosahuje 4 chyb v klasifikaci N signálů. Podobnost chybovosti na N signálech s ostatními klasifikátory je 42 %. Úspěšnost klasifikace se liší ve srovnání s neuronovou sítí o méně jak 1 %. Oba klasifiká-

tory dosahují senzitivity  $SE = 100 \%$ . S využitím více svodů přesnost této klasifikace klesá.

Použití SVM klasifikátorů se ukázalo jako nevýhodné. Dosahuje ve srovnání s ostatními metodami menší přesnosti  $ACC = 90,7 \%$  a především statisticky velice významné senzitivity  $SE = 84,3 \%$ . Určení N signálů bylo velice úspěšné, ovšem prediktivita je daleko méně významná pro tuto problematiku.

Velikou nevýhodou klasifikátorů KNN a SVM je, že namnožená množina trénovacích dat pro určení KES nepřispívá k rozptylu mezi daty. Tyto klasifikátory plně nevyužijí množství trénovacích dat.


V rámci hodnocení EKG signálů byl vytvořen klasifikátor, pro klasifikaci jednotlivých srdečních cyklů (viz. Obr. 8.3). Srdeční cykly byly rozděleny do dvou skupin. První skupina obsahovala fyziologické kmity, druhá skupina kmity patologické. Zeleň označení určuje fyziologické srdeční cykly a červené vyznačení udává patologický srdeční cyklus. Klasifikátorem je zde neuronová síť, kde na vstupu nacházíme již dříve nalezené příznaky. Pro řešení této problematiky bylo nutné anotovat jednotlivé srdeční cykly. Tato vlastní anotace proběhla na základě poznatku z literatury [11]. Ovšem toto určení je stále nutno pokládat za subjektivní. Jedná se o přibližné určení patologických kmitů.



Obr. 8.3: Přibližné určení patologických kmitů

S odbornou anotací (komplex od komplexu) by bylo možné tuto metodu použít pro klasifikaci N, KES, LBBB, RBBB a určení dalších patologií.

Přesnost klasifikace BBB, KES a N naznačuje obrázek (viz. Obr. 8.4)



Obr. 8.4: Chybovost klasifikátorů N, KES a BBB signálů

Klasifikátor relativně správně určuje N signály, ovšem dochází k časté záměně KES a N. Pro zlepšení klasifikace by bylo vhodnější anotovat signály komplex od komplexů a využít tak potenciál výše uvedené klasifikace. Zvýšení přesnosti klasifikace by bylo možné na základě vytvoření podmínky, která upřesňuje, že patologie KES a BBB se nemůže současně nacházet v jednom krátkém úseku signálu.

## Závěr

V této práci byla popsána elektrická srdeční aktivita, komorové extrasystoly, arytmie a komorové tachykardie. Následně bylo pojednáno o současných detektorech KES. Detekce komorových extrasystol je procesem, kterému předchází předzpracování, segmentace, výběr příznaků a následná klasifikace. Signál byl filtrován filtrem pro odstranění kolísání nulové izolinií a následně segmentován dle R kmitů. Byly realizovány tři metody pro výběr příznaků. První metoda využívá přibližného rozměření signálu. Bere v úvahu každý srdeční cyklus a zjišťuje délky, maximální amplitudy a obsahy pod křivkou kmitů P, R a T. U kmitu Q zjišťuje pouze obsah pod křivkou. Následná metoda vybírá příznaky pomocí analýzy hlavních komponent ze zarovnaných segmentů signálu. Poslední uskutečněná metoda se opírá o starší studie. Využívá příznaků jako RR intervaly, amplitudy kmitů P, R, T a korelaci s reprezentativním vzorem sinusového signálu. Veškeré příznaky jsou normalizované Z – funkcí. Jako klasifikátor byla použita dopředná neuronová síť, metoda k – nejbližších sousedů a metoda podpurných vektorů. Nejlepších výsledků bylo dosaženo metodou PCA segmentů s klasifikátorem: dopředná neuronová síť, konkrétně přesnost  $ACC = 98,5 \%$ , senzitivity  $SE = 100 \%$  a specificity  $SP = 96,1 \%$ . Následně byl vytvořen detektor pro detekci blokády Tawarova raménka, KES a N signálů. Tento klasifikátor využíval příznaky z metod zaměřených na detekci KES. Pro klasifikaci BBB Bylo dosaženo přesnosti  $ACC = 79,4 \%$ , KES přesnost  $ACC = 85,6 \%$  a přesnost detekce N signálů je  $ACC = 93,8 \%$ . (viz.Tab.- Vyhodnocení klasifikace BBB, KES a N)

# Literatura

- [1] ASCHERMANN, Michael, Petr WIDIMSKÝ, Josef VESELKA, Aleš LINHART a Jiří KRUPÍČKA. *Kardiologie*. 2004. Praha: Galén, 2004. ISBN 80-726-2290-0.
- [2] KITTNAR, Otomar. *Lékařská fyziologie*. Praha: Grada, 2011. ISBN 978-80-247-3068-4.
- [3] MOUREK, Jindřich. *Fyziologie: učebnice pro studenty zdravotnických oborů*. 2., dopl. vyd. Praha: Grada, 2012. Sestra (Grada). ISBN ISBN978-80-247-3918-2.
- [4] GOODENOUGH, D. A. a D. L. PAUL. Gap Junctions. *Cold Spring Harbor Perspectives in Biology*. 2009, **1**(1), a002576-a002576. DOI: 10.1101/cshperspect.a002576. ISSN 1943-0264.
- [5] OpenStax College. (2013). Anatomy and physiology. Houston, TX: OpenStax CNX. Dostupné z <http://cnx.org/content/col11496/latest/>
- [6] *Cardiac conduction system: Cardiac Embryology* [online]. 2010 [cit. 2020-01-02].
- [7] GANONG, William F. *Přehled lékařské fyziologie*. Jinočany: HH, 1995. ISBN 80-857-8736-9.
- [8] ALGHATRIF, Majd a Joseph LINDSAY. A brief review: history to understand fundamentals of electrocardiography. *Journal of Community Hospital Internal Medicine Perspectives*. 2012, **2**(1), all. DOI: 10.3402/jchimp.v2i1.14383. ISSN 2000-9666.
- [9] DOC. ING. JIŘÍ KOZUMPLÍK, CSC, Jiří. *Analýza biologických signálů*. Brno, 2012. Skripta. VUT.
- [10] WINTER, JASON. ECG Educator Blog. *ECG Educator Blog* [online]. 2016 [cit. 2019-11-12].
- [11] BENNETT, David H. *Srdeční arytmie: praktické poznámky k interpretaci a léčbě*. Osmé. Praha: Grada, 2014. ISBN OSBN978-80-247-5134-4.
- [12] *Lékařská fyziologie*. Praha: Grada, 1994. ISBN 80-716-9036-8.
- [13] FOLKERINGA, R. J. Atrial extrasystoles after exercise predict atrial fibrillation in patients with left ventricular hypertrophy. *Heart*. 2005, **92**(4), 545-546. DOI: 10.1136/hrt.2005.069542. ISSN 1355-6037.

- [14] GAZTAÑAGA, Larraitz, Francis E. MARCHLINSKI a Brian P. BETENSKY. Mechanisms of Cardiac Arrhythmias. *Revista Española de Cardiología (English Edition)*. 2012, **65**(2), 174-185. DOI: 10.1016/j.rec.2011.09.020. ISSN 18855857.
- [15] KUCK, K-H, M SCHLUTER, M GEIGER, J SIEBELS a W DUCKECK. Radiofrequency current catheter ablation of accessory atrioventricular pathways. *The Lancet*. 1991, **337**(8757), 1557-1561. DOI: 10.1016/0140-6736(91)93258-B. ISSN 01406736.
- [16] THAKOR, N.V. a Y.-S. ZHU. Applications of adaptive filtering to ECG analysis: noise cancellation and arrhythmia detection. *IEEE Transactions on Biomedical Engineering*. **38**(8), 785-794. DOI: 10.1109/10.83591. ISSN 00189294.
- [17] LUZ, Eduardo José da S., William Robson SCHWARTZ, Guillermo CÁMARA-CHÁVEZ a David MENOTTI. ECG-based heartbeat classification for arrhythmia detection: A survey. *Computer Methods and Programs in Biomedicine*. 2016, (127), 144-164. DOI: 10.1016/j.cmpb.2015.12.008. ISSN 01692607.
- [18] ZHANG, Zhancheng, Jun DONG, Xiaoqing LUO, Kup-Sze CHOI a Xiaojun WU. Heartbeat classification using disease-specific feature selection. *Computers in Biology and Medicine*. 2014, **46**, 79-89. DOI: 10.1016/j.compbimed.2013.11.019. ISSN 00104825.
- [19] *Association for the Advancement of Medical Instrumentation: AAMI* [online]. Arlington [cit. 2019-12-20]. Dostupné z: <https://www.aami.org/index.aspx>
- [20] JOSHI, S. L., R. A. VATTI a R. V. TORNEKAR. A Survey on ECG Signal Denoising Techniques. *2013 International Conference on Communication Systems and Network Technologies*. IEEE, 2013, 2013, , 60-64. DOI: 10.1016/j.compbimed.2013.11.019. ISBN 978-1-4673-5603-9.
- [21] BANKMAN, Isaac N. Introduction to Segmentation. *Handbook of Medical Imaging*. Elsevier, 2000, 2000, , 67-68. DOI: 10.1016/B978-012077790-7/50008-4. ISBN 9780120777907.
- [22] DE CHAZAL, Philip, Maria O-DWYER a Richard B. REILLY. Automatic Classification of Heartbeats Using ECG Morphology and Heartbeat Interval Features. *IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING*. 2004, **první**(51), all.
- [23] DE LANNOY, G., D. FRANCOIS, J. DELBEKE a M. VERLEYSEN. Weighted Conditional Random Fields for Supervised Interpatient Heartbeat Classification. *IEEE Transactions on Biomedical Engineering*. 2012, **59**(1), 241-247. DOI: 10.1109/TBME.2011.2171037. ISSN 0018-9294.

- [24] LIN, Chun-Cheng a Chun-Min YANG. Heartbeat Classification Using Normalized RR Intervals and Morphological Features. *Mathematical Problems in Engineering*. 2014, **2014**, 1-11. DOI: 10.1155/2014/712474. ISSN 1024-123X.
- [25] ZHANG, Zhancheng, Jun DONG, Xiaoqing LUO, Kup-Sze CHOI a Xiaojun WU. Heartbeat classification using disease-specific feature selection. *Computers in Biology and Medicine*. 2014, **46**, 79-89. DOI: 10.1016/j.combiomed.2013.11.019. ISSN 00104825.
- [26] KAYA, Yasin a Hüseyin PEHLIVAN. Classification of Premature Ventricular Contraction in ECG. *International Journal of Advanced Computer Science and Applications*. 2015, **6**(7), 34-40. DOI: 10.14569/IJACSA.2015.060706. ISSN 21565570.
- [27] SINGH, Brij N. a Arvind K. TIWARI. Optimal selection of wavelet basis function applied to ECG signal denoising. *Digital Signal Processing*. 2006, **16**(3), 275-287. DOI: 10.1016/j.dsp.2005.12.003. ISSN 10512004.
- [28] PARENT, Rick. Interpolating Values. *Computer Animation*. Elsevier, 2012, 2012, , 61-109. DOI: 10.1016/B978-0-12-415842-9.00003-4. ISBN 9780124158429.
- [29] MELOUN, Milan a Jiří MILITKÝ. *Statistická analýza experimentálních dat*. Vyd. 2., upr. a rozš. Praha: Academia, 2004. ISBN 80-200-1254-0.
- [30] HARUŠTIAKOVÁ, Danka. *Vícerozměrné statistické metody v biologii*. Brno: Akademické nakladatelství CERM, 2012. ISBN ISBN:978-80-7204-791-8.
- [31] CEYLAN, Rahime a Yüksel ÖZBAY. Comparison of FCM, PCA and WT techniques for classification ECG arrhythmias using artificial neural network. *Expert Systems with Applications*. 2007, **33**(2), 286-295. DOI: 10.1016/j.eswa.2006.05.014. ISSN 09574174.
- [32] SARFRAZ, Mohammad, Ateeq Ahmed KHAN a Francis F. LI. Using independent component analysis to obtain feature space for reliable ECG Arrhythmia classification. *2014 IEEE International Conference on Bio-informatics and Biomedicine (BIBM)*. IEEE, 2014, 2014, , 62-67. DOI: 10.1109/BIBM.2014.6999249. ISBN 978-1-4799-5669-2.
- [33] M.A., Jarno a Jari J. Independent Component Analysis in ECG Signal Processing. *Advances in Electrocardiograms - Methods and Analysis*. InTech, 2012, 2012-01-25. DOI: 10.5772/22719. ISBN 978-953-307-923-3.

- [34] KOZUMPLÍK, CSC, Doc. Ing. Jiří a Prof. Ing. Ivo PROVAZNÍK, PH.D. *Umělá inteligence v medicíně*. Brno, 2007. Skripta. VUT.
- [35] KABÁTH, David. *Úvod do umělé inteligence: NEURONOVÉ SÍTĚ ZÁKLADY Z TEORIE A PRAXE*. 2009. Referát.
- [36] HOLČÍK, Jiří, KOMENDA, Martin (eds.) a kol. *Matematická biologie: e-learningová učebnice* [online]. 1. vydání. Brno: Masarykova univerzita, 2015. ISBN 978-80-210-8095-9.
- [37] OIKARINEN, L, M KARVONEN, M VIITASALO, et al. Electrocardiographic assessment of left ventricular hypertrophy with time-voltage QRS and QRST-wave areas. *Journal of Human Hypertension*. 2004, 18(1), 33-40. DOI: 10.1038/sj.jhh.1001631. ISSN 0950-9240.



# Seznam symbolů, veličin a zkratek

<b>SA uzel</b>	sinoatriální uzel
<b>AV uzel</b>	atrioventrikulární uzel
<b>EKG</b>	elektrokardiogram- záznam elektrické aktivity srdce
<b>ISCH</b>	ischemická choroba srdeční
<b>KES</b>	komorová extrasystola
<b>ICD</b>	kardioverterydefibrilátor
<b>N</b>	normální úder
<b>S</b>	supraventrikulární ektopický úder
<b>V</b>	komorový ektopický úder
<b>F</b>	sloučení komorového a normálního úderu
<b>Q</b>	úder, který neodpovídá výše zmíněným skupinám
<b>brum</b>	rušení elektrického vedení
<b>pre-R úsek</b>	úsek před kmitem R
<b>post-R úsek</b>	úsek po kmitu R
<b>PCA</b>	Analýza hlavních komponent neboli Principal Component Analysis
$\lambda$	vlastní hodnota - metoda PCA
<b>u</b>	vlastní vektor - metoda PCA
<b>ICA</b>	analýza nezávislých komponent
<b>NN</b>	neuronové síť
<b>SVM</b>	metoda podprných vektor
<b>EPSP</b>	excitační postsynaptický potenciál
<b>KNN</b>	Metoda k- nejbližších sousedů
<b>ABSC</b>	prostor s fixním polem se stíním podle Arnolda a Barnetta
<b>pozitivní signál</b>	pozitivní signál vzniklý medianovou filtrací - metoda přibližného rozměření
<b>negativní signál</b>	negativní signál vzniklý medianovou filtrací - metoda přibližného rozměření
<b>BBB</b>	Raménkové blokády
<b>LBBB</b>	Blokáda levého Tawarova raménka
<b>RBBB</b>	Blokáda pravého Tawarova raménka

# A Obsah elektronických příloh

## A.1 Vstupní data - databáze ÚBMI

- BTLdataq.mat
- annotVutArray.mat
- annotVut.mat

Vytvořené klasifikátory byly navrženy a testovány v softwaru Matlab 2017b.

## A.2 Seznam funkcí a potřebných dat ke klasifikaci

Skripty určené ke spuštění detektorů.

- **klasifikaceNaKES.m** - skript pro klasifikaci KES a N signálů
- **klasifikaceNaKESaBBB.m** - skript pro klasifikaci KES, N a BBB signálů
- **klasifikacesrdecnichcyklu.m** - skript pro klasifikaci patologických srdečních cyklů
- další funkce
  
- **vyhodnoceni.m** - fce pro vyhodnocení klasifikace N/ KES signálů
- **filtrace.m** - fce pro filtraci signálů
- **testovaniKNN.m** - fce pro hledání optimálního počtu k nejbližších sousedů
- **delkynove2.m** - fce pro přibližné rozměření signálů
- **vyhodnoceni2.m** - fce pro vyhodnocení klasifikace N/KES/BBB signálů
- **vyberrhythmPVCBBBNN.m** - fce pro výběr N/KES/BBB signálů
- **vyberrhythmfinal.m** - fce pro výběr N/KES signálů
- **segmentace.m** - segmentace signálu se zarovnáním segmentů
- **segmentace2.m** - segmentace signálu bez zarovnání segmentů
- **normalizace.m** - normalizace příznaků
- **vyberpatologickychkmitu.m** - funkce pro výběr patologických srdečních cyklů
- **RRint.m** - funkce pro rozměření RR intervalů
- **konkretnisignal.m** - funkce vybírá jednotlivé signály
- **amp.m** - funkce pro rozměření amplitudových intervalů
- **pcam.m** - funkce s odkazem na PCA
- **sinus-prav.mat** - reprezentativní segment N signalu
- **sigma.m** - data reprezentující "sigmu" pro Z funkcí (normalizace), načteno z trénovacích dat
- **sigma.m** - data reprezentující "mi" pro Z funkcí (normalizace), načteno z trénovacích dat

## A.3 Seznam vytvořených klasifikátorů

Klasifikaci KES a N.

- **d41.mat** - ANN - přibližné rozměření:svody(II,V-1 a V-6))
- **1331.mat** - ANN- Přibližné rozměření:svody(II) + ANN:svody(II,V-1 a V-6)
- **svm2.mat** - SVM:svody(II)
- **g4.mat'** - ANN:svody(II)
- **MDLNEW.mat** - KNN:svody(II)
- **snn2.mat** - ANN - KONVENČNÍ METODY:svod (II)
- **SVM3svody** - SVM: svody(II,V-1 a V-6)
- **l6.mat** - ANN:svody(II,V-1 a V-6)
- **MDL3svody.mat** - KNN:svody(II,V-1 a V-6)

Klasifikaci KES, N a BBB.

- **b2833.mat** - ANN klasifikace N/KES/BBB

Výběr patologických srdečních cyklů.

- **SVMStruct2** - SVM - výběr patologických srdečních cyklů
- **unn2.mat** - ANN - výběr patologických srdečních cyklů